

UNIVERSIDADE FEDERAL DO PARANÁ

ANDREY AUGUSTO ALVES DE OLIVEIRA

GERAÇÃO DE NUVEM DE PONTOS POR DECOMPOSIÇÃO GAUSSIANA DA
FULL-WAVEFORM DO SINAL LASER COM ALGORITMOS GENÉTICOS E
CLASSIFICAÇÃO FUZZY

CURITIBA

2018

ANDREY AUGUSTO ALVES DE OLIVEIRA

GERAÇÃO DE NUVEM DE PONTOS POR DECOMPOSIÇÃO GAUSSIANA DA
FULL-WAVEFORM DO SINAL LASER COM ALGORITMOS GENÉTICOS E
CLASSIFICAÇÃO FUZZY

Tese apresentada ao Programa de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientador: Prof. Dr. Jorge Antonio Silva Centeno.

CURITIBA

2018

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

O48g

Oliveira, Andrey Augusto Alves de

Geração de nuvem de pontos por decomposição Gaussiana da Full-waveform do sinal laser com algoritmos genéticos e classificação Fuzzy / Andrey Augusto Alves de Oliveira. – Curitiba, 2018.


Tese - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas, 2018.

Orientador: Jorge Antonio Silva Centeno.

1. Algoritmos genéticos. 2. Lógica difusa. 3. Feixes de laser. I. Universidade Federal do Paraná. II. Centeno, Jorge Antonio Silva. III. Título.

CDD: 511.8

Bibliotecária: Vanusa Maciel CRB- 9/1928




MINISTÉRIO DA EDUCAÇÃO
SETOR CIÊNCIAS DA TERRA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO CIÊNCIAS
GEODÉSICAS

TERMO DE APROVAÇÃO

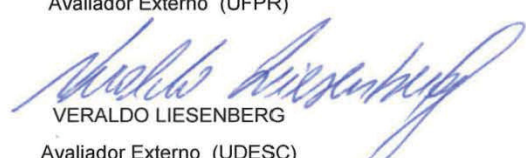
Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em CIÊNCIAS GEODÉSICAS da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **ANDREY AUGUSTO ALVES DE OLIVEIRA** intitulada: **GERAÇÃO DE NUVEM DE PONTOS POR DECOMPOSIÇÃO GAUSSIANA DA FULL-WAVEFORM DO SINAL LASER COM ALGORITMOS GENÉTICOS E CLASSIFICAÇÃO FUZZY**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 23 de Fevereiro de 2018.


JORGE ANTONIO SILVA CENTENO
Presidente da Banca Examinadora (UFPR)


CHRISTEL LINGNAU
Avaliador Externo (UFPR)


VERALDO LIESENBERG
Avaliador Externo (UDESC)


HIDEO ARAKI
Avaliador Interno (UFPR)

Dedico este trabalho aos meus pais.

AGRADECIMENTOS

À minha família, namorada e amigos pelo incentivo e apoio.

Ao Professor Jorge Antonio Silva Centeno pela orientação, conhecimento transmitido, paciência e amizade.

Aos Professores do Programa de Pós-Graduação em Ciências Geodésicas, coordenação e todos que contribuíram para a minha formação.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo fomento.

À divisão de Geossoluções do Instituto de Tecnologia para o Desenvolvimento (LACTEC), ao gerente Fabiano e a pesquisadora Johanna que destinaram tempo para a extração e esclarecimentos sobre os dados. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelos subsídios para a importação, previstos na Lei 8010/90, L. I. 12 / 1846474-1.

Ao Instituto Federal Catarinense pela concessão de afastamento integral no último semestre para a finalização do curso de doutorado.

Aos componentes da banca avaliadora que contribuíram com importantes observações para a melhoria desta tese.

25°10'45" S

49°08'07" O

RESUMO

Os sistemas convencionais de mapeamento topográfico com a tecnologia LIDAR registram até cinco retornos na forma discreta. Avanços tecnológicos ocorridos nas últimas décadas proporcionaram o desenvolvimento de sistemas LIDAR full-waveform que digitalizam completamente o sinal de retorno. Instalado em aeronave sobrevoando a 1.000 metros de altura, o feixe LASER emitido por estes sistemas gera footprint pequeno, com diâmetro variando entre 0,2 m e 0,8 m. Quando o feixe intercepta parcialmente diferentes alvos, múltiplos retornos podem ser determinados dependendo da metodologia utilizada para a detecção dos picos na waveform. Estes picos contêm informações sobre as características físicas das superfícies iluminadas, tais como a refletividade, rugosidade, altura e inclinação. Pesquisas têm sido realizadas para a detecção dos picos empregando diferentes técnicas, tais como a decomposição, deconvolução e correlação entre os sinais emitido e recebido. Nesta tese foi desenvolvida uma metodologia para a decomposição Gaussiana das waveforms com Algoritmos Genéticos e classificação dos pontos com abordagem Fuzzy. Os dados foram medidos sobre área urbana com edificações, estrada de asfalto, solo exposto, vegetação arbórea e rasteira. Com os Algoritmos Genéticos foi realizado o processo de busca e otimização dos parâmetros de amplitude, desvio padrão e tempo, cujos valores iniciais foram estimados em algoritmo de simples detecção de picos com ponto de máximo local. As distâncias dos alvos foram calculadas utilizando o tempo e, no processo de georreferenciamento a partir dos parâmetros de emissão do feixe LASER, determinaram-se as coordenadas dos pontos no sistema geodésico de referência. Foram realizados dois experimentos aplicando a metodologia de decomposição Gaussiana das waveforms e em ambos houve aumento na quantidade de pontos, respectivamente de 16,9 % e 18,1 %, em comparação com as nuvens de pontos geradas por software comercial, os melhores resultados ocorreram em áreas de vegetação arbórea. A classificação dos pontos foi realizada com Lógica Fuzzy utilizando os parâmetros de amplitude e desvio padrão, a inferência foi implementada com o método Mamdani e a desnebulização ocorreu pelo método do centroide, nos dois experimentos as acurácias globais foram de 86,0 % e 86,7 %, comprovando a viabilidade da metodologia desenvolvida.

Palavras-chave: Lidar Full-Waveform, Decomposição Gaussiana, Algoritmos Genéticos, Lógica Fuzzy.

ABSTRACT

Conventional topographic LIDAR systems record up to five returns in the discrete-form. Technological advances in the last decades have impelled the development of full-waveform LIDAR systems that digitize the whole return signal of the emitted LASER pulse. These systems installed in aircraft flying at 1,000 meters high generate small footprints with a diameter ranging from 0.2 m to 0.8 m. When the LASER beam partially illuminate different targets, multiple returns can be determined depending on the methodology used for the peaks detection in the waveform. These peaks contain information about the physical characteristics of the illuminated surfaces, such as reflectivity, roughness, height and slope. Several researches have been carried out to detect the peaks using different techniques such as decomposition, deconvolution and correlation between the emitted and received signals. In this doctoral thesis was developed a methodology for the Gaussian decomposition of the waveform with Genetic Algorithms and points classification using Fuzzy approach. The waveforms data were measured on an urban area with buildings, asphalt road, exposed soil, arboreal and undergrowth vegetation. The Genetic Algorithms were used in the search and optimization process of Gaussian parameters, the initial values were estimated in a simple peak detection algorithm with the maximum local point method. For each detected peak the amplitude, standard deviation and time parameters were determined. The targets distances were calculated using the time and, in the georeferencing procedure using the LASER beam emission parameters, the coordinates of the points were determined in the geodetic reference system. Two experiments were performed applying the Gaussian decomposition of the waveforms methodology and there was an increase in the number of points, respectively of 16.9% and 18.1%, compared to the points cloud generated by commercial software, the best results were obtained in areas with arboreal vegetation. The points classification was performed with Fuzzy Logic using the parameters of amplitude and standard deviation, the inference was implemented with the Mamdani method and the defuzzification with the centroid method, in the two experiments were obtained overall accuracy of 86.0% and 86.7%, proving the viability of the methodology developed.

Keywords: Lidar Full-Waveform, Gaussian Decomposition, Genetic Algorithms, Fuzzy Logic.

LISTA DE FIGURAS

FIGURA 2.1 – MÉTODO DO TEMPO DE PERCURSO	23
FIGURA 2.2 – MÉTODO DA DIFERENÇA DE FASE DO SINAL.....	25
FIGURA 2.3 – DISPOSITIVOS DE VARREDURA	26
FIGURA 2.4 – PADRÕES DE VARREDURA.....	26
FIGURA 2.5 – COMPONENTES DO SISTEMA ALS	28
FIGURA 2.6 – MAPEAMENTO COM SISTEMA ALS.....	29
FIGURA 2.7 – DECOMPOSIÇÃO DO FOOTPRINT	31
FIGURA 2.8 – FOOTPRINT DO SISTEMA LVIS	33
FIGURA 2.9 – FORMAS DE REGISTRO DO SINAL DE RETORNO	35
FIGURA 2.10 – AMOSTRAS DE WFS.....	36
FIGURA 2.11 – DIGITALIZAÇÃO BINÁRIA DA WF.....	36
FIGURA 2.12 – MODELAGEM GAUSSIANA DA WF	37
FIGURA 2.13 – PARÂMETROS DA EQUAÇÃO DO RADAR	39
FIGURA 2.14 – MODELO SIMPLIFICADO PARA REFLEXÃO DA RADIAÇÃO.....	40
FIGURA 2.15 – RINGING EFFECT.....	42
FIGURA 2.16 – MÉTODOS DE DETECÇÃO DO PULSO	43
FIGURA 2.17 – REGISTRO COM O MÉTODO DO LIMIAR.....	44
FIGURA 2.18 – MODELAGEM COM A FUNÇÃO GAUSSIANA.....	47
FIGURA 2.19 – ASSINATURAS ESPECTRAIS	51
FIGURA 2.20 – WFS CARACTERÍSTICAS	52
FIGURA 2.21 – SISTEMA ALTM PEGASUS HD500	53
FIGURA 2.22 – PONTO DE REFERÊNCIA DO ALTM PEGASUS HD500	54
FIGURA 2.23 – SISTEMAS REFERENCIAIS DO ALTM PEGASUS HD500	54
FIGURA 2.24 – FAIXAS DE OPERAÇÃO DO ALTM PEGASUS HD500.....	56
FIGURA 2.25 – INTELLIGENT WAVEFORM DIGITIZER	58
FIGURA 2.26 – WF COMPLEXA COM 3 RETORNOS DETECTADOS	60
FIGURA 2.27 – WF COMPLEXA COM 4 RETORNOS DETECTADOS	61
FIGURA 2.28 – TEMPO DE PERCURSO EM WF SIMPLES.....	62
FIGURA 2.29 – SISTEMAS REFERENCIAIS DE COORDENADAS EM ALS	64
FIGURA 2.30 – SISTEMAS REFERENCIAIS DE COORDENADAS DO INS E UL ..	65
FIGURA 2.31 – CROMOSSOMO COM 12 GENES	70
FIGURA 2.32 – FLUXOGRAMA DOS ALGORÍTIMOS GENÉTICOS	72
FIGURA 2.33 – VALORES UTILIZADOS EM LÓGICA BOOLEANA E FUZZY.....	73

FIGURA 3.1 – ÁREA DE ESTUDO	81
FIGURA 3.2 – NUVEM DE PONTOS	82
FIGURA 4.1 – ETAPAS DA METODOLOGIA	84
FIGURA 4.2 – CROMOSSOMO COM 12 BITS.....	86
FIGURA 4.3 – CROMOSSOMO COM 37 BITS.....	87
FIGURA 4.4 – FLUXOGRAMA DA DECOMPOSIÇÃO GAUSSIANA COM AG	88
FIGURA 4.5 – CINCO RETORNOS MODELADOS COM GAUSSIANAS.....	90
FIGURA 4.6 – WF SIMPLES.....	91
FIGURA 4.7 – WF COMPLEXA	92
FIGURA 4.8 – WFS GERADAS POR RETORNOS ÚNICOS.....	94
FIGURA 4.9 – WFS GERADAS POR QUINAS DE TELHADOS.....	96
FIGURA 4.10 – WFS GERADAS POR VEGETAÇÃO ARBÓREA	98
FIGURA 4.11 – HISTOGRAMAS DE AMPLITUDE E DESVIO PADRÃO	101
FIGURA 4.12 – CLASSIFICAÇÃO DOS PONTOS POR AMPLITUDE	102
FIGURA 4.13 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L101.....	103
FIGURA 4.14 – PONTOS DA LINHA L101 CLASSIFICADOS.....	104
FIGURA 4.15 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L110.....	105
FIGURA 4.16 – PONTOS DA LINHA L110 CLASSIFICADOS.....	105
FIGURA 4.17 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L116.....	106
FIGURA 4.18 – PONTOS DA LINHA L116 CLASSIFICADOS.....	106
FIGURA 4.19 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L122.....	107
FIGURA 4.20 – PONTOS DA LINHA L122 CLASSIFICADOS.....	107
FIGURA 4.21 – CLASSIFICAÇÃO DOS PONTOS POR DESVIO PADRÃO	108
FIGURA 4.22 – ETAPAS DA CLASSIFICAÇÃO FUZZY.....	111
FIGURA 4.23 – MÉTODO MAMDANI	112
FIGURA 5.1 – ÁREA DO EXPERIMENTO 1.....	116
FIGURA 5.2 – PERFIL DA LINHA L101	118
FIGURA 5.3 – NUVEM DE PONTOS CLASSIFICADA DO EXPERIMENTO 1.....	119
FIGURA 5.4 – ÁREA DO EXPERIMENTO 2.....	121
FIGURA 5.5 – PERFIL DA LINHA DE PONTOS L219.....	123
FIGURA 5.6 – NUVEM DE PONTOS CLASSIFICADA DO EXPERIMENTO 2.....	124

LISTA DE QUADROS

QUADRO 2.1 – CARACTERÍSTICAS OPERACIONAIS DE SISTEMAS ALS FWF	34
QUADRO 2.2 – REGISTRO DISCRETO E DIGITALIZAÇÃO DA FWF	37
QUADRO 2.3 – FUNÇÕES ANALÍTICAS	49
QUADRO 2.4 – REFLETIVIDADE DE MATERIAIS	50
QUADRO 2.5 – ESPECIFICAÇÕES TÉCNICAS DO ALTM PEGASUS HD500	55
QUADRO 2.6 – PRECISÃO PLANIMÉTRICA	55
QUADRO 2.7 – ESPECIFICAÇÕES TÉCNICAS DO IWD	58
QUADRO 2.8 – AMOSTRAS DE AMPLITUDE DA WF	62
QUADRO 3.1 – PARÂMETROS DO VOO	82
QUADRO 3.2 – NUVEM DE PONTOS DO SOFTWARE DDR	83
QUADRO 3.3 – AMOSTRA DE WF	83
QUADRO 4.1 – INFORMAÇÕES DA NUVEM DE PONTOS GERADA	89
QUADRO 4.2 – PARÂMETROS DAS WFS COM RETORNOS ÚNICOS	95
QUADRO 4.3 – PARÂMETROS DAS WFS DE QUINAS DE TELHADOS	97
QUADRO 4.4 – PARÂMETROS DAS WFS DE VEGETAÇÃO ARBÓREA	99
QUADRO 4.5 – VARIÁVEIS LINGÜÍSTICAS	109
QUADRO 4.6 – REGRAS PARA A CLASSIFICAÇÃO FUZZY 1: RU	110
QUADRO 4.7 – REGRAS PARA A CLASSIFICAÇÃO FUZZY 2: RM	110
QUADRO 4.8 – MATRIZ DE CONFUSÃO	113
QUADRO 4.9 – CLASSES DE DESEMPENHO COM O COEFICIENTE KAPPA	115

LISTA DE TABELAS

TABELA 2.1 – COMPARAÇÃO DAS DISTÂNCIAS CALCULADAS	63
TABELA 4.1 – DISTÂNCIAS CALCULADAS PARA A WF SIMPLES	92
TABELA 4.2 – DISTÂNCIAS CALCULADAS PARA A WF COMPLEXA.....	93
TABELA 5.1 – QUANTITATIVO DE PONTOS DO EXPERIMENTO 1	117
TABELA 5.2 – MATRIZ DE CONFUSÃO DO EXPERIMENTO 1	119
TABELA 5.3 – ERROS DE OMISSÃO E INCLUSÃO NO EXPERIMENTO 1	120
TABELA 5.4 – QUANTITATIVO DE PONTOS DO EXPERIMENTO 2.....	122
TABELA 5.5 – MATRIZ DE CONFUSÃO DO EXPERIMENTO 2.....	124
TABELA 5.6 – ERROS DE OMISSÃO E INCLUSÃO NO EXPERIMENTO 2	125

LISTA DE ABREVIATURAS E SIGLAS

A	- Amplitude
AG	- Algoritmos Genéticos
ALB	- Airborne Laser Bathymetry
ALS	- Airborne Laser Scanning
ALTM	- Airborne Laser Terrain Mapper
ASCII	- American Standard for Computer Information Interchange
ASDF	- Averaged Square Difference Function
ASPRS	- American Society for Photogrammetry and Remote Sensing
CG	- Centro de Gravidade
DDAR	- Software Digitizer Data Acquisition and Recording
DDR	- Software Digitizer Data Retrieval
DG	- Decomposição Gaussiana
DGNSS	- Differential Global Navigation Satellite System
EA	- Estrada de Asfalto
EAARL	- Experimental Advanced Airborne Research Lidar
FOV	- Field Of View
FWF	- Full-Waveform
GNSS	- Global Navigation Satellite System
GPS	- Global Positioning System
GSFC	- Goddard Space Flight Center
IFOV	- Instantaneous Field Of View
INS	- Inertial Navigation System
IWD	- Intelligent Waveform Digitizer
LADAR	- LAsEr Detection And Ranging
LADS	- Laser Airborne Depth Sounder
LASER	- Light Amplification by Stimulated Emission of Radiation
LF	- Lógica Fuzzy
LIDAR	- Light Detection And Ranging
LMS	- Lidar Mapping Suite
LVIS	- Laser Vegetation Imaging Sensor
MDT	- Modelo Digital de Terreno

MDS	- Modelo Digital de Superfície
MDSN	- Modelo Digital de Superfície Normalizado
ML	- Máximo Local
MPIA	- Multiple Pulses In Air
NASA	- U. S. National Aeronautics and Space Administration
ND	- Níveis Digitais
Nd:YAG	- Neodymium-doped: Yttrium Aluminium Garnet
PML	- Ponto de Máximo Local
PRF	- Pulse Repetition Frequency
RADAR	- RAdio Detection And Ranging
SDP	- Simples Detecção de Picos
SE	- Solo Exposto
SHOALS	- Scanning Hydrographic Operational Airborne Lidar Survey
SIRGAS2000	- Sistema de Referência Geocêntrico para as Américas 2000
SLICER	- Scanning Lidar Imagery of Canopies by Echo Recovery
TC	- Telhado de Cerâmica
TF	- Telhado de Fibrocimento
TGPS	- Tempo GPS
TLS	- Terrestrial Laser Scanning
TOF	- Time-Of-Flight
UTM	- Universal Transversa de Mercator
VA	- Vegetação Arbórea
VR	- Vegetação Rasteira
WF	- Waveform
WGS84	- World Geodetic System 1984

SUMÁRIO

1	INTRODUÇÃO	18
1.1	HIPÓTESE	20
1.2	OBJETIVOS	21
1.2.1	Objetivo geral	21
1.2.2	Objetivos específicos.....	21
1.3	JUSTIFICATIVA.....	21
2	REVISÃO DE LITERATURA.....	23
2.1	MEDIDA DE DISTÂNCIA.....	23
2.2	DISPOSITIVOS DE VARREDURA.....	26
2.3	SISTEMAS ALS.....	27
2.4	PARÂMETROS DO MAPEAMENTO COM SISTEMAS ALS.....	28
2.5	FULL-WAVEFORM.....	32
2.6	EQUAÇÃO DO RADAR.....	38
2.7	PROCESSAMENTO DA WF	41
2.7.1	Ruído	41
2.7.2	Ringling effect.....	42
2.7.3	Simples detecção de picos	42
2.7.4	Correlação do sinal.....	45
2.7.5	Deconvolução	45
2.7.6	Decomposição	46
2.8	RESPOSTA ESPECTRAL.....	50
2.9	ALTM PEGASUS HD500.....	53
2.10	DIGITIZER.....	58
2.11	GEORREFERENCIAMENTO	64
2.12	ALGORITMOS GENÉTICOS.....	68
2.13	LÓGICA FUZZY.....	73
2.14	ESTADO DA ARTE	75
3	MATERIAIS.....	81
4	METODOLOGIA.....	84
4.1	DECOMPOSIÇÃO GAUSSIANA COM ALGORITMOS GENÉTICOS	85
4.2	WAVEFORMS CARACTERÍSTICAS.....	93
4.3	CLASSIFICAÇÃO FUZZY	100
4.3.1	Análise de amplitude	102

4.3.2	Análise de desvio padrão	108
4.3.3	Variáveis linguísticas	109
4.3.4	Inferência Fuzzy	111
4.4	AVALIAÇÃO DA QUALIDADE DA CLASSIFICAÇÃO	113
5	RESULTADOS E ANÁLISES.....	116
5.1	EXPERIMENTO 1.....	116
5.2	EXPERIMENTO 2.....	121
6	CONSIDERAÇÕES FINAIS	126
6.1	CONCLUSÕES.....	126
6.2	RECOMENDAÇÕES	128
	REFERÊNCIAS BIBLIOGRÁFICAS	130

1 INTRODUÇÃO

A tecnologia Light Detection And Ranging (LIDAR) possibilita medir a distância de objetos a partir da emissão de luz. O cálculo da distância entre o sensor e o alvo é realizado através do tempo de percurso do pulso emitido, na forma de feixe LASER (Light Amplification by Stimulated Emission of Radiation), e refletido pela superfície iluminada (WEHR e LOHR, 1999).

Os sistemas LASER aerotransportados, Airborne Laser Scanning (ALS), utilizam a tecnologia LIDAR para medir as distâncias dos alvos e como produtos são geradas nuvens de pontos com coordenadas tridimensionais georreferenciadas (MALLET et al., 2009). Uma das principais vantagens dos sistemas ALS é possibilidade do pulso LASER penetrar o dossel nas florestas, o que proporciona a medição de pontos no terreno localizado abaixo das copas das árvores (WAGNER et al., 2004).

Os sistemas ALS tradicionais registram o sinal de retorno na forma discreta e medem a distância das superfícies que estejam afastadas entre si pelo menos 1 metro. Nas últimas décadas aumentaram-se as aplicações para os dados provenientes de sistemas ALS devido às inovações tecnológicas. A densidade dos dados levantados foi aumentada devido as maiores frequências de aquisição e varredura, além do desenvolvimento de sistemas com múltiplos pulsos emitidos simultaneamente. A partir de voos com 1.000 m de altura e com footprints pequenos, diâmetros variando de 0,2 a 1 m, a precisão nas medidas de distâncias melhorou. Além dos mapeamentos topográficos os dados provenientes de aerolevantamentos com sistemas ALS também são utilizados na modelagem tridimensional de áreas urbanas e florestas (WAGNER et al., 2006).

Sistemas ALS full-waveform realizam a completa digitalização do sinal de retorno através da amostragem da waveform, normalmente realizada com taxa de 1 nano segundo (WAGNER et al., 2006). A ocorrência de múltiplos picos no sinal de retorno indica que mais alvos foram interceptados para o mesmo pulso emitido. Sistemas ALS FWF são capazes de registrar estes retornos (MALLET et al., 2009).

Os dados contidos na waveform possibilitam a extração de informações para a identificação de espécies em florestas, estrutura vertical, determinação da altura do dossel (ALEXANDER et al., 2014), saúde, volume de madeira, biomassa (FERRAZ et al., 2016), forma, densidade, além da detecção de diferentes níveis de

vegetação de baixo porte (BLAIR et al., 1999). Com a waveform também é possível reconhecer a topografia do terreno e de feições arqueológicas em áreas arborizadas (DONEUS et al., 2008).

Diversas pesquisas foram realizadas sobre a decomposição da waveform do sinal de retorno com o objetivo de obter informações com significado físico dos alvos, tais como a inclinação e a proporção do feixe LASER que foi refletido (LIN et al., 2008). No entanto, para a obtenção destas informações, são necessárias novas metodologias para a geração e classificação dos pontos, pois em grande parte dos softwares comerciais os algoritmos processam apenas os dados registrados na forma discreta.

Dentre as vantagens da utilização de sistemas ALS full-waveform para aplicações topográficas, cita-se a geração de Modelo Digital de Terreno (MDT) com maior densidade de pontos. Isto possibilita localizar descontinuidades nas superfícies de acordo com a dimensão do footprint, distinguir o terreno e vegetação baixa com até um metro de altura. Também são obtidos parâmetros sobre a refletividade das superfícies dos alvos atingidos, estes proporcionam a detecção da rugosidade e inclinação das superfícies atingidas pelo feixe LASER, e consequentemente, a classificação dos pontos em áreas vegetadas ou edificadas. Estas informações também podem ser utilizadas para o monitoramento de encostas suscetíveis a desmoronamentos e em análises de obstruções para as atividades aeronáuticas (ZALETNYIK et al., 2010).

Segundo Toth et al. (2011) a waveform possibilita identificar mais alvos atingidos pelo mesmo feixe LASER, informações detalhadas sobre a inclinação e rugosidade das superfícies, maior flexibilidade e controle no processamento, melhor interpretação dos dados e cálculo das distâncias dos alvos em pós-processamento. Como desvantagem ocorre o aumento no tamanho dos arquivos com as amostras de waveform quando comparados aos registrados na forma discreta, maior tempo de processamento e poucos softwares disponíveis.

A digitalização da waveform produz uma série de números associados à variação da amplitude do sinal de retorno ao longo do tempo. O problema, neste caso, é deduzir a partir desta série de dados a presença de retornos causados por uma ou várias superfícies de objetos que foram atingidos pelo feixe LASER. Quando apenas um objeto é atingido, a série de dados apresenta um pico bem definido e relativamente fácil de ser identificado. O tempo associado a este pico permite

calcular a distância do objeto. Quando mais de um objeto é iluminado pelo sistema ocorrem vários picos na série de dados e objetiva-se a detecção dos mesmos. O maior problema é verificado quando os objetos se encontram muito próximos no percurso do feixe LASER, pois neste caso os picos podem estar sobrepostos e serem confundidos. Outro aspecto relevante é que a forma e a amplitude de cada pico dependem das características da superfície iluminada, sua geometria e reflectância, o que permite deduzir informações a respeito dos objetos. Por estes motivos, a decomposição da waveform é um processo importante para o aumento da informação obtida. Na decomposição Gaussiana dos picos, os parâmetros de amplitude e desvio padrão definem a potência e a forma do sinal de retorno, a média corresponde ao tempo (posição) do pico no sinal de retorno e este é especialmente importante, pois define a distância da superfície iluminada pelo feixe LASER.

1.1 HIPÓTESE

Se a digitalização do sinal de retorno através da full-waveform (FWF) contém informações a respeito dos objetos iluminados pelo feixe LASER e é possível detectar, na série de dados da waveform (WF), parâmetros que descrevam estas informações, então estes parâmetros podem ser utilizados para classificar os pontos gerados. A solução proposta nesta tese utiliza a decomposição Gaussiana da WF com Algoritmos Genéticos (AG) para gerar a nuvem de pontos e a classificação desta através de abordagem baseada em regras e Lógica Fuzzy (LF).

A otimização da decomposição Gaussiana com AG proporciona solução com qualidade de acordo com a tolerância da função de aptidão (fitness) adotada. Com a LF é possível classificar os pontos gerados através de regras aplicadas sobre os parâmetros de amplitude e desvio padrão sem a definição de limites rígidos para as classes.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Desenvolver uma metodologia para geração de nuvem de pontos a partir da decomposição Gaussiana da waveform com otimização por Algoritmos Genéticos e classificação dos pontos utilizando os parâmetros de amplitude e desvio padrão em uma abordagem baseada em regras Fuzzy.

1.2.2 Objetivos específicos

- 1) Gerar a nuvem de pontos a partir da decomposição Gaussiana da waveform através da metodologia de busca e otimização com Algoritmos Genéticos;
- 2) Avaliar se houve aumento na quantidade de pontos determinados em relação à nuvem de pontos gerada por software comercial;
- 3) Definir as waveforms características das feições contidas na área de estudo;
- 4) Analisar os limites rígidos para as classes dos parâmetros de amplitude e desvio padrão e definir as variáveis linguísticas utilizadas nas regras da classificação Fuzzy;
- 5) Avaliar a qualidade da classificação dos pontos realizada.

1.3 JUSTIFICATIVA

Os primeiros sistemas ALS comerciais registravam apenas um retorno na forma discreta. Posteriormente passaram a registrar até cinco retornos. Avanços tecnológicos permitiram digitalizar o completo retorno do sinal através de sistemas ALS FWF (WAGNER et al., 2004). Outra evolução ocorreu nas frequências de operação e varredura. Um exemplo é o sistema que mediu os dados utilizados nesta tese, o Airborne Laser Terrain Mapper (ALTM) Pegasus HD500 fabricado pela Optech Incorporated. Este sistema apresenta frequências máximas de operação e perfilamento respectivamente de 500 kHz e 140 Hz, a digitalização da WF é realizada com 12 bits através do sistema Digitizer (OPTECH, 2012b).

Em áreas com vegetação arbórea, a digitalização da WF proporciona nuvens de pontos mais densas que as geradas com os sistemas ALS convencionais. Além

das coordenadas tridimensionais e da intensidade do sinal de retorno para cada ponto, podem ser obtidas informações sobre a refletividade e geometria do alvo atingido, ângulo de reflexão do feixe LASER e quantidade de energia contida no sinal de retorno (ZALETNYIK et al., 2010). A duração do pulso e a área do footprint na seção atingida pelo feixe LASER são outras informações que podem ser extraídas da WF para classificar os pontos (WAGNER et al., 2006).

Para obtenção de parâmetros com significado físico a respeito dos alvos é necessário que a WF seja decomposta através de funções apropriadas às características procuradas. Com isto, visando à classificação da nuvem de pontos, a reconstrução da WF é uma etapa a ser realizada antes da projeção ortogonal dos pontos. Esta etapa necessita das amostras de amplitude digitalizadas na WF do sinal de retorno (MALLET et al., 2009).

Além dos métodos de simples detecção de picos (SDP), no processamento da WF podem ser utilizadas técnicas de deconvolução ou decomposição (MALLET e BRETAR, 2009). Os algoritmos de decomposição da WF são utilizados para parametrizar os retornos contidos na WF com funções analíticas. A soma destas funções corresponde a WF modelada. Normalmente são utilizados métodos de SDP para estimar parâmetros iniciais. Posteriormente, estes parâmetros são ajustados em relação à curva da WF digitalizada através da função de aptidão em um processo iterativo. Consequentemente, o processamento de WFs com métodos de decomposição tendem a ser mais demorados que os métodos de SPD ou deconvolução (WANG et al., 2016).

No Brasil, a partir dos anos 2000, aumentou o número de empresas que realizam o recobrimento aerofotogramétrico simultaneamente com sistemas ALS, as nuvens de pontos geradas são um produto complementar às ortofotos e a digitalização da FWF possibilita extrair o completo potencial dos dados LIDAR. Em áreas com cobertura florestal os sistemas ALS FWF proporcionam maior quantidade de pontos em comparação aos sistemas ALS que registram os pontos na forma discreta, possibilitando o mapeamento de diferentes extratos e camadas de vegetação.

2 REVISÃO DE LITERATURA

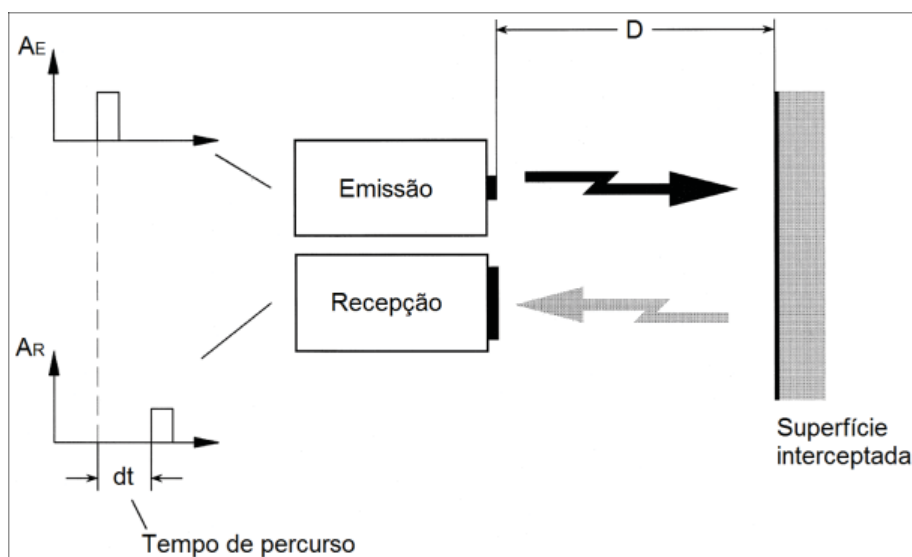
Neste capítulo são apresentados os métodos utilizados na medida de distância com a tecnologia LIDAR, sistema ALS e suas principais características, processamento da WF através da correlação de sinais, deconvolução e decomposição com funções analíticas, georreferenciamento das medidas, conceitos sobre Algoritmos Genéticos e Lógica Fuzzy.

2.1 MEDIDA DE DISTÂNCIA

As medidas de distância com iluminação LASER são realizadas através de dois métodos. O primeiro considera o tempo do percurso de pulsos curtos de energia. O segundo método utiliza a diferença de fase do sinal modelado na forma de onda contínua (WEHR e LOHR, 1999).

Sistemas que utilizam o primeiro método emitem um pulso LASER e medem o tempo de retorno ao sensor após ser refletido pela superfície do alvo. Este método é denominado por Time-Of-Flight (TOF) em grafia na língua inglesa (LANGE, 2000). A Figura 2.1 ilustra o método de medida de distância com o tempo de percurso de pulsos curtos de energia. O pulso emitido com amplitude (A_E) é recebido com amplitude (A_R) após ser refletido pela superfície interceptada.

FIGURA 2.1 – MÉTODO DO TEMPO DE PERCURSO



FONTE: Adaptado de Wehr e Lohr (1999).

Quanto melhor for a medida do tempo, melhor será a precisão da distância calculada, por este motivo o relógio do sensor é um fator muito importante. Para obter precisão métrica nas medidas de distância é necessário medir o tempo com precisão na ordem dos nano segundos (ns). A amplitude e duração do pulso são outros parâmetros importantes (LANGE, 2000).

No método do tempo de percurso à distância (D) de um alvo pode ser calculada através da Equação (2.1). Para isto, é necessário conhecer a variação de tempo (dt), entre a emissão e recepção do pulso, e o valor constante (c) da velocidade da luz (WEHR e LOHR, 1999).

$$D = c \cdot \frac{dt}{2} \quad (2.1)$$

Conforme demonstrado na Equação (2.2), a precisão (ΔD) da distância calculada é função da precisão na medida do tempo (Δdt).

$$\Delta D = c \cdot \frac{\Delta dt}{2} \quad (2.2)$$

O método da diferença de fase é utilizado para evitar a necessidade de medir o tempo com alta precisão. O sinal é emitido na forma de onda contínua com uma fonte de iluminação LASER. Esta fonte permite a modulação direta do sinal através da voltagem do sistema. Para a utilização do método da diferença de fase considera-se que o sinal refletido mantém a forma do sinal emitido, mas a fase de ambos é diferente (LANGE, 2000).


A diferença de fase é diretamente proporcional ao tempo de percurso do sinal, a partir desta suposição a distância do alvo pode ser calculada através da Equação (2.3). Para isto, é necessário conhecer a diferença de fase (φ), a frequência (f) de modulação do sinal emitido e o valor constante da velocidade da luz (c). A precisão da distância calculada (ΔD) é obtida através da Equação (2.4). É função da precisão na determinação da diferença de fase ($\Delta \varphi$) entre os sinais emitido e recebido (WEHR e LOHR, 1999).

$$D = \frac{1}{4\pi} \cdot \frac{c}{f} \cdot \varphi \quad (2.3)$$

$$\Delta D = \frac{1}{4\pi} \cdot \frac{c}{f} \cdot \Delta\varphi \quad (2.4)$$

A Figura 2.2 ilustra a medida de distância com o método da diferença de fase do sinal.

FIGURA 2.2 – MÉTODO DA DIFERENÇA DE FASE DO SINAL




FONTE: Adaptado de Wehr e Lohr (1999).

De acordo com Kersting (2011) o método da diferença de fase do sinal emitido na forma de onda contínua é mais utilizado em sistemas LASER terrestres (Terrestrial Laser Scanning - TLS).

2.2 DISPOSITIVOS DE VARREDURA

Segundo Wehr e Lohr (1999) os dispositivos de varredura tipicamente utilizados em sistemas ALS são o espelho oscilante, varredura Palmer, polígono de rotação e fibra óptica. Os três primeiros dispositivos são ilustrados na Figura 2.3.

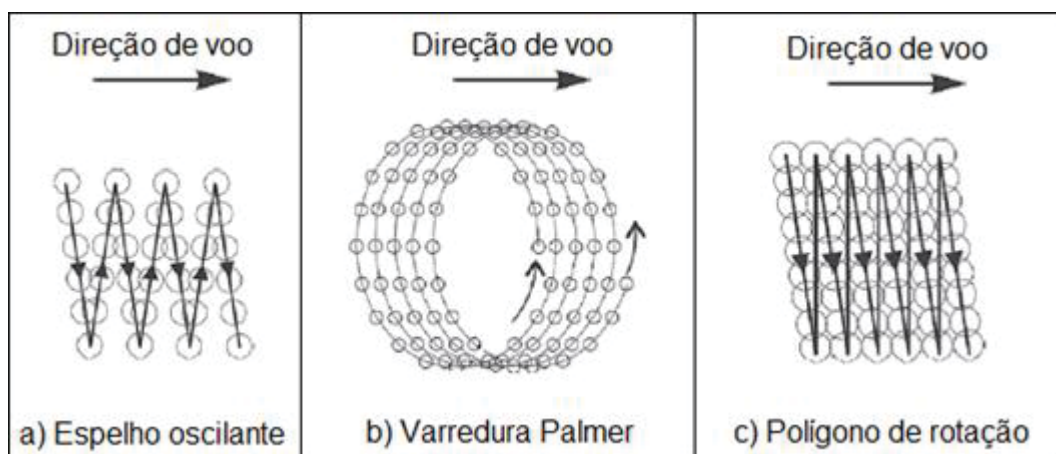
FIGURA 2.3 – DISPOSITIVOS DE VARREDURA



FONTE: Adaptado de Wehr e Lohr (1999).

Os padrões de varredura gerados com os dispositivos da Figura 2.3 são ilustrados na Figura 2.4.

FIGURA 2.4 – PADRÕES DE VARREDURA



FONTE: Adaptado de Shan e Toth (2009).


2.3 SISTEMAS ALS

Sistemas ALS são utilizados em aerolevantamentos com objetivo de realizar o mapeamento tridimensional da superfície terrestre. Esta tecnologia também é conhecida por LIDAR ou LADAR (LAsER Detection And Ranging). Apresenta a vantagem de emitir pulsos com grande quantidade de energia em intervalos de tempo relativamente curtos, proporcionando alta densidade de medidas sobre os alvos interceptados. Para isto, utiliza uma unidade para emissão e recepção dos pulsos LASER (WEHR e LOHR, 1999).

Em sistemas ALS é comum a emissão de pulsos com um díodo LASER do tipo Nd:YAG (Neodymium-doped: Yttrium Aluminium Garnet). O pulso é emitido com duração variando de 5 a 15 ns, comprimento de onda entre 800 e 1.064 nm o que corresponde à faixa espectral do infravermelho próximo (WEHR e LOHR, 1999). Os parâmetros que caracterizam as propriedades físicas do pulso LASER em sistemas ALS são o comprimento de onda (μm), duração do pulso (ns) e quantidade de energia (μJ) (BALTSAVIAS, 1999).

Conhecendo-se a distância dos pontos e a trajetória da aeronave definida pelo sistema de posicionamento global por satélites GNSS (Global Navigation Satellite System) e de medida inercial INS (Inertial Navigation System) são obtidas as coordenadas dos pontos na superfície terrestre referenciadas ao sistema geodésico do mapeamento, normalmente o World Geodetic System 1984 (WGS84). A Figura 2.5 ilustra os componentes do sistema ALS, em varredura realizada com espelho oscilante em voo apoiado.

FIGURA 2.5 – COMPONENTES DO SISTEMA ALS



FONTE: Adaptado de Kersting (2011).

No voo apoiado são utilizados receptores GNSS de dupla frequência na aeronave e estação base. O método de posicionamento diferencial (Differential Global Navigation Satellite System – DGNSS) pós-processado é empregado para a correção das posições da aeronave durante o aerolevantamento. A partir da trajetória da aeronave definida pelos sistemas GNSS e INS, distância dos pontos e ângulo de disparo do pulso laser, realiza-se o georreferenciamento dos pontos medidos na varredura (MOSTAFA e HUTTON, 2001).


2.4 PARÂMETROS DO MAPEAMENTO COM SISTEMAS ALS

Sistemas ALS utilizam a tecnologia LIDAR para obter coordenadas tridimensionais de pontos sobre a superfície terrestre com alta densidade. As medidas de distâncias são realizadas de forma direta a partir do tempo de retorno do pulso LASER emitido. Atualmente, a maioria dos sistemas ALS disponíveis no mercado emitem feixes LASER com pulsos curtos, muita energia e alta frequência de repetição (KERSTING, 2011).

A Figura 2.6 ilustra os parâmetros envolvidos no mapeamento com um sistema ALS. O footprint corresponde à área atingida no terreno por um feixe

LASER. No aerolevantamento também são considerados os parâmetros operacionais como a frequência de operação (kHz), largura do feixe (mrad), ângulo de varredura ($^{\circ}$), frequência de varredura (Hz), altura de voo (m) e diâmetro (m) do footprint na superfície do terreno.

FIGURA 2.6 – MAPEAMENTO COM SISTEMA ALS



FONTE: Adaptado de Kersting (2011).

A largura (L) da faixa de recobrimento é função do ângulo de varredura (β) e da altura de voo (H), conforme a Equação (2.5).

$$L = 2 \cdot H \cdot \tan\left(\frac{\beta}{2}\right) \quad (2.5)$$

O footprint é função da divergência do feixe LASER, altura de voo, ângulo de varredura FOV (Field Of View) e declividade do terreno. A divergência do feixe LASER nos sistemas ALS varia entre 0,15 e 0,8 mrad. Objetiva-se que a divergência seja pequena nos mapeamentos de feições contidas em áreas urbanas, como na definição de bordas de edificações, ou em florestas onde se espera que o feixe passe pelo dossel para o mapeamento de pontos no terreno (BIN *et al.*, 2008).

Conhecendo-se a altura de voo (H), o diâmetro (D_t) de abertura do sistema de transmissão, o ângulo de divergência (γ), através da Equação (2.6) pode ser calculado o diâmetro do footprint (FP) do feixe LASER na superfície iluminada.

$$FP = D_t + 2 \cdot H \cdot \tan\left(\frac{\gamma}{2}\right) \quad (2.6)$$

De acordo com Wehr e Lohr (1999), a divergência define o ângulo de visão instantâneo (Instantaneous Field Of View – IFOV) do feixe LASER emitido e o limite físico para este é determinado pela difração da luz. O IFOV é função do comprimento de onda (λ) em que foi emitido o pulso LASER. Para uma luz espacialmente coerente, a difração do IFOV ($IFOV_{diff}$) pode ser calculada através da Equação (2.7).

$$IFOV_{diff} = 2,44 \cdot \frac{\lambda}{D_t} \quad (2.7)$$

O feixe LASER é emitido com alta potência de energia em sistemas ALS para ser bem direcionado. No entanto, por este motivo, o feixe pode ser nocivo para os olhos humanos, sendo assim uma curta faixa do espectro eletromagnético é utilizada, limitada entre 800 e 1.600 nm (WEHR e LOHR, 1999).


Considerando que a maior quantidade de energia encontra-se distribuída na área central do footprint, conhecendo-se o vetor normal (n) da superfície atingida e a direção (l) que o feixe LASER foi disparado, pode-se calcular o ângulo (α) de incidência do feixe LASER na superfície através da Equação (2.8). O vetor normal pode ser obtido de forma aproximada calculando o terceiro autovetor, a partir da matriz de variâncias e covariâncias de um conjunto de pontos representativos da superfície (SCHAER, 2010).

$$\alpha = \cos^{-1}\left(\frac{l \cdot n}{|l||n|}\right) \quad (2.8)$$

O footprint pode ser modelado pela elipse gerada na interseção do feixe LASER com o plano local tangente ao alvo. É à base do cone com origem (O),

direção (l) e ângulo de divergência (γ), conforme ilustra a Figura 2.7 (SCHAER, 2010).

FIGURA 2.7 – DECOMPOSIÇÃO DO FOOTPRINT



FONTE: Adaptado de Schaer (2010).

De acordo com Schaer (2010) o eixo principal do footprint, semieixo maior “a”, no espaço tridimensional pode ser decomposto nas direções horizontal e vertical máximas. Considerando a distribuição bivariada Gaussiana da energia contida no footprint, a incerteza posicional para os componentes horizontal e vertical da geometria do feixe LASER são expressas através das Equações (2.9) e (2.10).

$$\sigma_{xy}^{geom} = \frac{1}{3} \cdot \max \left\langle \left| \left[\frac{a_x}{a_y} \right] \right|, \left| \left[\frac{b_x}{b_y} \right] \right| \right\rangle \quad (2.9)$$

$$\sigma_z^{geom} = \frac{1}{3} \cdot \max \langle |[a_z]|, |[b_z]| \rangle \quad (2.10)$$

Outros parâmetros nos sistemas ALS são as frequências de perfilamento e operação. Estes são muito importantes principalmente para o planejamento de voo que é realizado considerando a densidade de pontos requerida no projeto. A

frequência de perfilamento define o número de varreduras realizadas por segundo. A taxa de repetição do sistema ALS (Pulse Repetition Frequency – PRF), corresponde à frequência de operação. O sistema ALTM Pegasus HD500 apresenta frequência de perfilamento máxima de 140 Hz, o que corresponde a 140 varreduras por segundo. É capaz de emitir até 500.000 pulsos LASER por segundo, a uma frequência de operação de 500 kHz.

Um fator limitante para aumentar a frequência de emissão é a duração do pulso emitido. Em um voo com altura de 1.500 m este tempo é de aproximadamente 10 μ s. Neste caso, os pulsos devem ser emitidos com frequência inferior a 100 kHz. Para aumentar a frequência de emissão foram desenvolvidas duas soluções. A primeira é a denominada MPIA (Multiple Pulses In Air) e consiste em emitir um novo pulso antes do retorno do anteriormente emitido. A segunda solução é mais robusta e consiste no uso de múltiplos sensores LASER em diferentes canais do sistema. O ALTM Pegasus HD500 é um exemplo de sistema que combina as duas soluções, MPIA e multicanal, e assim a frequência de operação foi aumentada para 500 kHz sem perder a qualidade nas medidas (KERSTING, 2011).

2.5 FULL-WAVEFORM

Os primeiros sistemas ALS FWF foram desenvolvidos na década de 1980 para a realização de levantamentos batimétricos. São denominados Airborne Laser Bathymetry (ALB) e também Laser Airborne Depth Sounder (LADS). Foram projetados para o mapeamento da topografia subaquática em águas costeiras e superficiais, para isto, emitem dois feixes LASER simultaneamente, nos comprimentos de onda 532 nm (verde) e 1.064 nm (infravermelho). O sistema LARSEN-500 desenvolvido pela Terra Surveys e Optech, é considerado o primeiro sistema ALB. Em seguida foram desenvolvidos os sistemas Scanning Hydrographic Operational Airborne Lidar Survey (SHOALS) da United State Army e Optech, o Experimental Advanced Airborne Research Lidar (EAARL) da United States National Aeronautics and Space Administration (NASA) e o Hawk Eye da Saab e Optech (MALLET e BRETAR, 2009).


Com objetivo de mapear áreas com cobertura florestal o Goddard Space Flight Center (GSFC), da NASA, desenvolveu os sistemas Scanning Lidar Imagery of Canopies by Echo Recovery (SLICER) e o Laser Vegetation Imaging Sensor (LVIS)

nas décadas de 1980 e 1990. Para isto, utilizaram a técnica de altimetria LASER e o completo registro do sinal de retorno. Estes sistemas experimentais utilizavam aeronaves como plataformas (BLAIR et al., 1999).

O sistema SLICER a 5 km de altura gera footprint com diâmetro de 10 m na direção do voo, o que possibilita distinguir superfícies afastadas entre 5 e 10 m. Emite pulsos LASER com duração de 4 ns, comprimento de onda de 1.064 nm e frequência de operação igual a 80 Hz. A WF é digitalizada com 0,742 ns e proporciona medidas de distância com precisão de 0,11 m (MEANS et al., 1999).

O sistema LVIS a 10 km de altura gera faixas com 1.000 m de largura e footprint de 25 m, conforme ilustrado na Figura 2.8. A WF do sinal de retorno pode ser totalmente digitalizada. Utiliza um díodo Nd:YAG para emitir pulsos LASER com 1.064 nm, duração de 10 ns, potência de 5 mJ e frequência de operação igual a 500 Hz. Realiza a medida do sinal de retorno em curtos intervalos de tempo, inferiores a 10 ns. Combinado com as informações de posição e atitude da aeronave, o LVIS é capaz de gerar nuvens de pontos para o mapeamento topográfico, além de proporcionar informações sobre a estrutura da vegetação (BLAIR et al., 1999).

FIGURA 2.8 – FOOTPRINT DO SISTEMA LVIS



FONTE: Blair et al. (1999).

Para serem medidos separadamente pelo sistema LVIS os alvos precisam estar separados de 0,3 m, considerando a frequência de operação de 500 Hz. Com esta amostragem é possível obter precisão vertical na modelagem de superfícies de 0,03 m, considerando que a forma do feixe LASER tenha distribuição amostral Gaussiana (HOFTON e BLAIR, 2002).

A taxa de amostragem típica nos sistemas ALS FWF é 1 ns, o que permite realizar medidas de distância com precisão de 0,15 m, considerando que a distância corresponde a metade do tempo de percurso do sinal. No entanto, a efetiva medida de distância com a WF depende da forma que o objeto refletiu o pulso LASER (TOTH et al., 2011). No Quadro 2.1 são apresentadas as principais características operacionais de alguns sistemas ALS FWF com fins de mapeamento topográfico.

QUADRO 2.1 – CARACTERÍSTICAS OPERACIONAIS DE SISTEMAS ALS FWF

SENSOR	LVIS ¹	SLICER ²	LMS-Q560 ³	FALCON III ⁴	MARK II ⁵	ALS60 ⁶	ALTM 3100 ⁷	ALTM PEGASUS HD500 ⁸
Altura de operação (km)	10	8	1,5	1,5	1,0	6,0	2,5	2,5
Resolução espectral (nm)	1.064	1.064	1.550	1.560	1.064	1.064	1.064	1.064
Largura do pulso (ns)	10	4	4	5	4	5	8	4
Energia do pulso (μJ)	5.000	700	8	-	-	200	200	250
Frequência de operação (kHz)	0,5	0,08	100	125	50	50	50	500
Frequência de varredura (Hz)	500	80	5 - 160	165 - 415	50	90	70	140
Divergência do feixe LASER (mrad)	8	2	0,5	0,7	1	0,22	0,3 - 0,8	0,25
FOV (°)	± 7	0 (Nadir)	± 22,5	28	14/20	75	± 25	± 32,5
Footprint (m) @ altura de voo (km)	40 @ 5	10 @ 5	0,5 @ 1	0,7 @ 1	1 @ 1	0,22 @ 1	0,3 e 0,8 @ 1	0,25 @ 1
Digitalização da WF (ns)	2	0,742	1	-	1	1	1	1

¹ LVIS. Fonte: Wagner et al. (2006).

² SLICER. Fonte: Means et al. (1999).

³ RIEGL LMS-Q560. Fonte: Wagner et al. (2006).

⁴ TOPOSYS FALCON III. Fonte: Mallet e Bretar (2009).

⁵ TOPEYE MARK II. Fonte: Mallet e Bretar (2009).


⁶ LEICA ALS60. Fonte: Mallet e Bretar (2009).

⁷ OPTECH ALTM 3100. Fonte: Wagner et al. (2006).

⁸ OPTECH ALTM PEGASUS HD500. Fonte: Optech (2012b) e Optech (2014).

Conforme ilustra a Figura 2.9, o registro do sinal de retorno pode ser realizado pela determinação discreta ou digitalização da WF.

FIGURA 2.9 – FORMAS DE REGISTRO DO SINAL DE RETORNO




FONTE: Adaptado de Doneus et al. (2008).

O registro do sinal de retorno na forma discreta ocorre nos pontos de máximo local, quando existem dois picos muito próximos um registro é feito com a média de ambos, conforme ilustrado na Figura 2.9 para a vegetação arbustiva e terreno. Na digitalização da WF são registradas amostras que permitem a modelagem da curva, e com isto, os sinais de retorno para as feições de vegetação

arbustiva e terreno podem ser detectados separadamente. A Figura 2.10 ilustra WFs dos sinais de retorno para cinco pulsos LASER emitidos consecutivamente.


FIGURA 2.10 – AMOSTRAS DE WFS



FONTE: Adaptado de Mallet et al. (2009).

A Figura 2.11 ilustra a digitalização binária da WF do sinal de retorno.


FIGURA 2.11 – DIGITALIZAÇÃO BINÁRIA DA WF



FONTE: Adaptado de Wagner et al. (2006).

No estudo de Wagner et al. (2006) foi realizada a decomposição da WF em séries de funções Gaussianas utilizando os parâmetros de amplitude (A), tempo médio (μ) e desvio padrão (σ). A Figura 2.12 ilustra a decomposição Gaussiana do último pico da WF do sinal de retorno.

FIGURA 2.12 – MODELAGEM GAUSSIANA DA WF



Fonte: O Autor (2018).

O Quadro 2.2 apresenta um comparativo entre o registro discreto e a digitalização da FWF.

QUADRO 2.2 – REGISTRO DISCRETO E DIGITALIZAÇÃO DA FWF

	REGISTRO DISCRETO	FWF
VANTAGENS	<ul style="list-style-type: none"> • Menor volume de dados e facilidade para utilização; • Processamento mais rápido; • Vários softwares disponíveis para o processamento. 	<ul style="list-style-type: none"> • Informações sobre a altura e inclinação das superfícies iluminadas pelo feixe LASER; • Registro de número “ilimitado” de alvos atingidos; • Maior controle e flexibilidade no processamento; • Possibilidade de definir a forma de calcular a distância dos alvos em pós-processamento, tornando o processo mais robusto.
DESvantagens	<ul style="list-style-type: none"> • Os alvos precisam estar separados pelo menos um metro para serem diferenciados; • O método de detecção do pulso no sinal de retorno é definido pelo fabricante; • Não é possível visualizar a WF nem como foram determinadas as distâncias medidas. 	<ul style="list-style-type: none"> • O volume dos dados aumenta de 50 a 200 vezes; • Maior tempo de processamento; • Poucas ferramentas disponíveis para o processamento dos dados.

FONTE: Adaptado de Toth et al. (2011).

2.6 EQUAÇÃO DO RADAR


Conceitos do RADAR (RADio Detection And Ranging) podem ser relacionados à medida da intensidade do sinal de retorno em sistemas ALS, pois são utilizados comprimentos de onda muito curtos para a emissão do pulso. A equação do RADAR é utilizada para converter a potência do sinal recebido em unidade de área da seção interceptada pelo feixe LASER, conforme expresso na Equação (2.11) é possível calcular a potência do sinal recebido considerando as características do sensor, alvo e atmosfera entre ambos (WAGNER et al., 2006).

$$P_r = \frac{P_t D_r^4}{4\pi D^4 \beta_t^2} \cdot n_{sis} \cdot n_{atm} \cdot \sigma \quad (2.11)$$

A potência do sinal recebido (P_r) é função da potência do pulso transmitido (P_t), diâmetro de abertura do receptor (D_r), distância (D) entre o sensor e o alvo, largura do feixe transmitido (β_t), seção transversal atingida no alvo (σ), fator de transmissão do sistema (n_{sis}) e fator atmosférico (n_{atm}), estes fatores correspondem às perdas de energia pelo sistema. Propriedades do alvo podem ser descritas pela área da seção transversal que causou o retroespalhamento do feixe LASER, considerando a intensidade e direção da reflexão.

Na Figura 2.13 são ilustrados os parâmetros envolvidos na equação do RADAR (WAGNER et al., 2004).

FIGURA 2.13 – PARÂMETROS DA EQUAÇÃO DO RADAR



FONTE: Adaptado de Wagner et al. (2006).


A modelagem da quantidade de energia contida no pulso proveniente do retorno causado por diferentes alvos é expressa na Equação (2.12), pode ser aplicada no retroespalhamento pontual em superfícies planas e no caso de alvos separados, onde o retroespalhamento ocorre a diferentes distâncias dentro do intervalo $[D_1, D_2]$, a intensidade do sinal registrada é o somatório dos retornos (WAGNER et al., 2004).

$$P_r(t) = \int_{D_1}^{D_2} \frac{D_r^2}{4\pi D^4 \beta_t^2} \cdot n_{sis} \cdot n_{atm} \cdot P_t \left(t - \frac{2D}{v_g} \right) \cdot \sigma(D) dD \quad (2.12)$$

Na Equação (2.12), o parâmetro (t) corresponde ao tempo, $(\sigma(D)dD)$ ao retroespalhamento diferencial da seção atingida e (v_g) representa a velocidade de grupo do pulso LASER na atmosfera. Para a radiação emitida com comprimentos de onda na faixa espectral do visível e infravermelho, considerando a atmosfera seca e que (v_g) varia no máximo 0,03 % do valor constante da velocidade da luz, pode-se fazer $(v_g \approx 3 \cdot 10^8 \text{ m} \cdot \text{s}^{-1})$. O termo $(2D/v_g)$ representa o tempo de percurso do pulso LASER (WAGNER et al., 2006).

A Figura 2.14 ilustra o retroespalhamento da radiação incidente em uma superfície através do modelo simplificado de cone para a reflexão em superfícies planas e rugosas. O padrão de retroespalhamento de radiação incidente é complexo, porém nesta simplificação, assume-se que a reflexão da radiação incidente sobre a área atingida da superfície (A_s) com refletividade (ρ), ocorre uniformemente conforme representado no cone com ângulo sólido (Ω), centrado no ponto de reflexão (WAGNER et al., 2006).

FIGURA 2.14 – MODELO SIMPLIFICADO PARA REFLEXÃO DA RADIAÇÃO



FONTE: Adaptado de Wagner et al. (2006).

O ângulo sólido é definido como a área percorrida sobre uma superfície esférica vista do centro desta. Para a reflexão do feixe LASER incidente, corresponde a características de rugosidade da superfície atingida. Para uma distância (D) entre o sistema ALS e o alvo, outras superfícies podem ser interceptadas pelo feixe causando retornos parciais do sinal no intervalo $[D_1, D]$. Assumindo que estes retornos parciais não contribuam significativamente para o retorno total do sinal, ($d\sigma$) representa a seção efetiva do alvo interceptado, iluminado apenas no retorno (dD). Considerando a hipótese que 90 % da área do footprint do feixe LASER tenha sido refletido pelas folhas e galhos de uma árvore, a seção transversal efetiva atingida no terreno seria igual a 10 % (WAGNER et al., 2004).

O retroespalhamento da seção (σ) interceptada pelo feixe LASER é apresentado na Equação (2.13), função da área (A_s), refletividade (ρ) e ângulo sólido

(Ω) da superfície refletora. O ângulo sólido representa a rugosidade desta superfície (WAGNER et al., 2006).

$$\sigma = \frac{4\pi}{\Omega} \rho A_s \quad (2.13)$$

As características de retroespalhamento do alvo dependem da área atingida, refletividade e rugosidade da superfície refletora. Os valores de intensidade não sofrem influencia de sombras causadas por nuvens, não dependem das condições de iluminação ou posição do sensor em relação ao sol (WAGNER et al., 2006).

2.7 PROCESSAMENTO DA WF

O processamento da WF pode ser realizado com métodos de simples detecção de picos, correlação, deconvolução e decomposição (MALLET et al., 2009). Nas seções a seguir, são brevemente descritos o ruído, ringing effect e os citados métodos de processamento.

2.7.1 Ruído

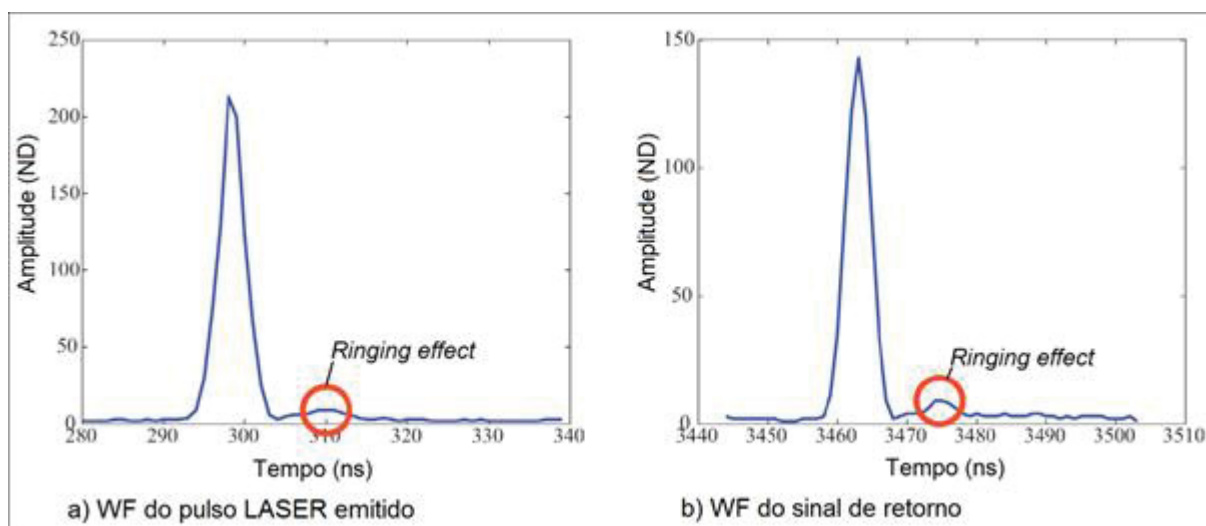
O sinal de retorno pode apresentar uma parcela de ruído que é digitalizado com a WF. Este é causado por diferentes fontes, tais como a temperatura da superfície do alvo, atmosfera ou imperfeições na fabricação do sensor. Quando a potência do sinal de retorno é fraca, próxima ao valor da amplitude do ruído, a detecção dos picos na WF torna-se difícil. Esta é uma situação crítica que pode ocorrer em áreas de vegetação arbórea, onde existe maior sobreposição de retornos (JUTZI e STILLA, 2006).

Diferentes técnicas são aplicadas para reduzir o ruído, tais como a acumulação do sinal ou a média móvel, nesta é considerado que ruídos aleatórios apresentam média igual à zero. No entanto, estas técnicas podem suavizar os picos e distorcer a WF (WU, 2012).

2.7.2 Ringing effect

O ringing effect é caracterizado na WF quando existe um pico muito baixo logo após um pico com grande valor de amplitude, conforme ilustra a Figura 2.15 (NORDIN, 2006).

FIGURA 2.15 – RINGING EFFECT



FONTE: Adaptado de Roncat et al. (2008).

A saturação do fotodiodo no sensor causa o ringing effect. Se este for detectado como um pico terá distância maior que a superfície iluminada pelo feixe LASER, caracterizando um erro de medida grosseiro (GUMEROV, 2014).

A modelagem da WF do sinal de retorno é mais difícil quando existe forte presença de ruído ou ringing effect. Com isto, a duração do pulso não é bem determinada, pois existe sobreposição de picos no sinal de retorno. O atraso causado por este efeito pode ser de 10 a 14 ns e corresponde a erros na medida de distância entre 1,5 e 2,1 m. A solução encontrada para este problema foi o uso de técnicas de correlação entre o pulso emitido e o sinal recebido. Com isto, os pontos de máxima do pulso LASER emitido devem ser identificados utilizando métodos de simples detecção de picos (RONCAT et al., 2008).


2.7.3 Simples detecção de picos

Métodos de simples detecção de picos (SDP) são utilizados na determinação da distância de alvos a partir da WF do sinal de retorno. Proporcionam

o processamento mais rápido da WF, porém picos sobrepostos podem ser omitidos (ZHU et al., 2011).

Tradicionalmente são utilizadas funções de limiar, centro de gravidade, ponto de máximo local (PML), cruzamento com o zero da segunda derivada e com uma constante de fracionamento. A Figura 2.16 ilustra pontos detectados no pulso emitido e também na WF do sinal de retorno, estes pontos são utilizados para estimar o tempo de percurso do sinal (WAGNER et al., 2004).

FIGURA 2.16 – MÉTODOS DE DETECÇÃO DO PULSO



FONTE: Adaptado de Wagner et al. (2004).


A Figura 2.16 ilustra os pulsos emitido e refletido pela seção interceptada. Também é apresentada a diferença dos tempos de percurso do sinal que foram estimados de acordo com a função utilizada na detecção do pulso. A amplitude (A) representa a potência (P_r) que o sinal de retorno foi recebido. A linha tracejada

horizontal com amplitude igual a 0,2 indica o limite utilizado no método do limiar (WAGNER et al., 2004).

Para determinar a distância de um objeto com precisão, o pulso detectado no sinal refletido deve ser relacionado com o pulso emitido. Isto é feito aplicando a mesma função para detectar o pulso em ambos os sinais. Na Figura 2.16, as diferenças de tempo medidas, e consequentes distâncias, deveriam ser 60 ns e 9 m para os pulsos detectados com as cinco funções. No entanto, sendo de 1 ns o intervalo amostral da WF e utilizando o método do limiar, o tempo de percurso estimado foi de 59,7 ns. O erro de 0,3 ns multiplicado pela precisão de 0,15 m resulta no erro de 0,045 m na medida de distância (WAGNER et al., 2004).

O método do limiar é um dos mais simples para o registro do retorno do pulso. Desde que o pulso emitido tenha amplitude acima do limiar definido, serão registrados os retornos com amplitude superior a este. O limiar deve ser superior à amplitude de ruídos presentes no sinal de retorno para que não haja erro grosseiro nas medidas de distância (WAGNER et al., 2004). A Figura 2.17 ilustra os retornos registrados com o método do limiar.

FIGURA 2.17 – REGISTRO COM O MÉTODO DO LIMIAR



FONTE: Adaptado de Slota (2014).

2.7.4 Correlação do sinal

Técnicas de correlação entre os sinais emitido e recebido permitem reduzir o tempo de processamento na estimação dos parâmetros iniciais de modelagem, proporcionam boa qualidade na determinação de distâncias, porém informações contidas na WF podem ser perdidas (ZHU et al., 2011).

A WF apresenta forma diferente do modelo assumido para o pulso LASER emitido. Isto ocorre devido à perda de energia do sinal de retorno e também pela sobreposição de picos (LIN et al., 2008).

Uma técnica utilizada para resolver este problema é a correlação cruzada normalizada (R_{norm}) expressa na Equação (2.14). Esta relaciona a WF do pulso emitido $s(t)$ e do sinal recebido $r(t)$ em função do atraso de tempo (τ) entre ambas (BRETAR et al., 2008).

$$R_{norm}(\tau) = \frac{\int_{t=-\infty}^{\infty} s(t) \cdot r(t+\tau) dt}{\sqrt{\int_{t=-\infty}^{\infty} s^2(t) dt \cdot \int_{t=-\infty}^{\infty} r^2(t) dt}} \quad (2.14)$$

2.7.5 Deconvolução

A interação do feixe LASER com a superfície do alvo atingido pode ser expressa com a equação do Radar. A potência contida no sinal é estimada através da convolução do sinal de retorno, conforme a Equação (2.12).

A forma do sinal de retorno é afetada pela série de convoluções. Quanto maior a série, menor a precisão na determinação da seção iluminada pelo feixe LASER. Isto pode ser resolvido com a deconvolução da Equação (2.15), sem a utilização de filtros no domínio da frequência. É obtida derivando o sinal recebido (P_r), ignorando fatores atmosféricos e removendo os termos constantes que não afetam a forma da WF (HARSDORF e REUTER, 2000).

$$P_r(t) = R(t - t') P_\delta(t') dt' + N(t) = (R(t) \times P_\delta(t)) + N(t) \quad (2.15)$$

O parâmetro $R(t)$ representa a contribuição do sistema e a convolução da WF do feixe LASER emitido, (P_δ) corresponde à área da seção atingida pelo feixe e $N(t)$ é o termo adicionado devido à presença de ruído.

A deconvolução da WF é realizada no domínio Fourier e o filtro de Wiener é utilizado para a estimação da função de modelagem do ruído a partir do sinal emitido (MALLET et al., 2009). Outras abordagens utilizam o ajustamento com a técnica de Levenberg-Marquardt, algoritmo de Richardson-Lucy, transformada de Fourier ou aplicam o Método dos Mínimos Quadrados Não Negativos (WU, 2012).

2.7.6 Decomposição

A decomposição da WF do sinal de retorno utilizando funções paramétricas apropriadas é uma das técnicas que demandam maior tempo de processamento, pois requer a estimação de parâmetros iniciais e uma etapa de otimização. No entanto, possibilita a extração de informações adicionais sobre a superfície iluminada pelo feixe LASER (ZHU et al., 2011). A determinação dos parâmetros que definem os picos da WF é realizada através de função analítica (f_j), conforme a Equação (2.16).

$$y = \sum_{j=1}^n f_j(x) \quad (2.16)$$


No entanto, para realizar a decomposição da WF através de funções analíticas são necessários parâmetros iniciais. A estimação destes parâmetros pode ser feita utilizando um método de SDP com PML. Em um processo iterativo, a curva modelada com a função analítica e os parâmetros iniciais é posteriormente ajustada a forma da curva amostrada com os dados da WF. De acordo com Slota (2014), as funções analíticas normalmente utilizadas para a decomposição da WF são a Gaussiana, Gaussiana Generalizada, Lognormal, Weibull, Nakagami e Burr.

A modelagem da WF com a função Gaussiana (f_G), expressa na Equação (2.17), é feita com os parâmetros de amplitude (A_j), tempo médio (μ_j) e desvio padrão (σ_j) para cada pico (j) contido na WF. O desvio padrão corresponde à largura do pico (WAGNER et al., 2006).

$$f_{G,j}(x) = A_j \cdot \exp\left(-\frac{(x-\mu_j)^2}{2\sigma_j^2}\right) \quad (2.17)$$

A Figura 2.18 ilustra as curvas geradas por funções Gaussianas com valores de amplitude e média iguais a 1 e 5, respectivamente. Para modelar as três curvas foram utilizados desvios padrão com os seguintes valores: 0,5; 1,0; e 2,0.

FIGURA 2.18 – MODELAGEM COM A FUNÇÃO GAUSSIANA



FONTE: O Autor (2018).

O tempo médio (μ_j) na Figura 2.18 corresponde à posição do pico no eixo das abscissas, considerando o domínio do tempo. Quanto maior o valor de desvio padrão (σ_j), mais larga a base do pico. De acordo com o estudo de Wagner et al. (2006) os três parâmetros da função Gaussiana (A, μ, σ) são suficientes para a modelagem de WFs simétricas. Na maioria das WFs obtidas com sistemas ALS com footprint pequeno, a decomposição Gaussiana apresenta bons resultados, no referido estudo apenas 2 % das WFs não puderam ser modeladas com esta função e nestes casos seria necessário utilizar parâmetros de funções mais complexas para a decomposição.

Para a modelagem da WF deve ser acrescentado à função Gaussiana um valor que corresponde ao ruído (R). Quando a WF do sinal de retorno apresenta mais de um pico, este pode ser representado pela soma das gaussianas que o compõe, conforme a Equação (2.18). Nesta equação o parâmetro (R_i) é uma constante (MALLET e BRETAR, 2009).

$$y = \sum_{j=1}^n f_j(x) + R \quad (2.18)$$

Segundo Chauve et al. (2007) a decomposição Gaussiana proporciona bons resultados quando o feixe LASER emitido e a WF do sinal de retorno possuem distribuição Gaussiana e o footprint é pequeno. No entanto, quando esta distribuição não pode ser assumida funções como a Gaussiana Generalizada e a Lognormal podem ser utilizadas. A função Gaussiana Generalizada (f_{GG}), expressa na Equação (2.19), pode ser utilizada na modelagem de picos sobrepostos através do parâmetro de planicidade (α).

$$f_{GG,j}(x) = A_j \cdot \exp\left(-\frac{|x-\mu_j|^{\alpha_j^2}}{2\sigma_j^2}\right) \quad (2.19)$$

Com a função Lognormal (f_L), expressa na Equação (2.20), podem ser modeladas curvas assimétricas, geradas pela reflexão do feixe LASER em áreas urbanas com superfícies inclinadas de telhados ou estradas pavimentadas. O parâmetro (s_j) corresponde ao fator de escala (CHAUVE et al., 2007).

$$f_{L,j}(x) = A_j \cdot \exp\left(-\frac{(\ln(x-s_j)-\mu_j)^2}{2\sigma_j^2}\right) \quad (2.20)$$

A função Weibul (f_W), expressa na Equação (2.21), possibilita a modelagem de curvas assimétricas através dos parâmetros (k_j) e (λ_j), que correspondem à forma e a escala (SLOTA, 2014).

$$f_{W,j}(x) = A_j \cdot \frac{k_j}{\lambda_j} \cdot \left(-\frac{(x-\mu_j)^{k_j-1}}{\lambda_j}\right) \cdot \exp\left(-\frac{|x-\mu_j|^{k_j}}{\lambda_j}\right) \quad (2.21)$$

A Equação (2.22) expressa a função Nakagami (f_N), esta realiza a modelagem de curvas que apresentem níveis de inclinação (skew) à direita ou a esquerda do ponto máximo do pico. Os parâmetros (ξ_j) e (ω_j) correspondem à escala e a forma, ($\Gamma(\xi_j)$) representa a função densidade de probabilidade Gama (SLOTA, 2014).

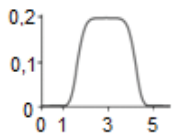
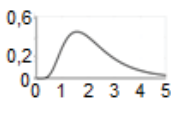
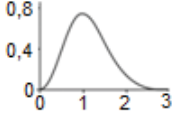
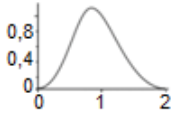
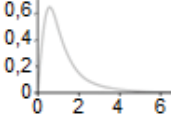
$$f_{N,j}(x) = A_j \cdot \frac{2\xi_j^{\xi_j}}{\omega_j \Gamma(\xi_j)} \cdot \left(-\frac{(x-\mu_j)^{2\xi_j-1}}{\omega_j}\right) \cdot \exp\left(-\xi_j \frac{|x-\mu_j|^{k_j}}{\omega_j}\right) \quad (2.22)$$

Com a função Burr (f_B), expressa na Equação (2.23), é feita a modelagem de curvas com inclinação à direita do pico. O parâmetro (a_j) corresponde à escala e os parâmetros (b_j) e (c_j) são os parâmetros que modelam a forma da curva (SLOTA, 2014).

$$f_{B,j}(x) = A_j \cdot \frac{b_j c_j}{a_j} \cdot \left(-\frac{(x - \mu_j)^{-b_j - 1}}{a_j} \right) \cdot \left(1 + \frac{|x - \mu_j|^{-b_j}}{a_j} \right)^{-c_j - 1} \quad (2.23)$$

No Quando 2.3 são apresentadas as propriedades das referidas funções analíticas, parâmetros e forma das curvas geradas.

QUADRO 2.3 – FUNÇÕES ANALÍTICAS

FUNÇÃO	a) GAUSSIANA GENERALIZADA	b) LOGNORMAL	c) WEIBUL	d) NAKAGAMI	e) BURR
PARÂMETROS	$A = 1;$ $\mu = 3;$ $\sigma = 2;$ $\alpha = 3;$	$A = 1;$ $\mu = 2;$ $\sigma = 0,5;$ $s = 1;$	$A = 1;$ $\mu = 0;$ $\kappa = 2;$ $\lambda = 1;$	$A = 1;$ $\mu = 0;$ $\xi = 2;$ $\omega = 1;$	$A = 1;$ $\mu = 0;$ $a = 1;$ $b = 2;$ $c = 1;$
PROPRIEDADE	Parâmetros de forma e planicidade.	Parâmetros de forma e escala.	Parâmetros de escala e assimetria.	Parâmetros de escala e inclinação.	2 parâmetros de forma e 1 de escala.
FORMA					

FONTE: Adaptado de Mallet et al. (2009).

Chauve et al. (2007) utilizaram as funções Gaussiana, Gaussiana Generalizada e Lognormal na modelagem de WFs medidas com footprint de 0,25 m, pelo sistema Riegl LMS-Q560, em área urbana e com vegetação densa. Realizaram a comparação desta modelagem através do estimador calculado através das diferenças residuais entre a WF observada e a modelada, o número de amostras e o número de parâmetros da função. Quando o valor do estimador foi inferior a 0,5 a modelagem dos picos contidos na WF com a função Gaussiana foi considerada satisfatória, com 99,3 % das WFs modeladas. No entanto, quando o estimador foi superior a 0,5 observaram que a WF é assimétrica, proveniente de superfícies inclinadas de telhados e neste caso os autores recomendam a modelagem com as funções a Lognormal, Gaussiana e Gaussiana Generalizada de forma conjunta.

No estudo de Mallet et al. (2009) foi realizada a modelagem de WFs, medidas em áreas urbanas e com vegetação, utilizando o algoritmo Reversible Markov Chain Monte Carlo com as funções Gaussiana Generalizada, Weibul Nakagami e Burr. Verificaram que a modelagem de picos levemente assimétricos sobrepostos, especialmente o segundo pico, foi possível com a função Burr.

2.8 RESPOSTA ESPECTRAL

A resposta espectral corresponde à refletividade da superfície iluminada com o feixe LASER. O sensor deve ser escolhido de acordo com os fenômenos que se pretende analisar. No Quadro 2.4 estão descritos os valores de refletividade para as superfícies de alguns materiais determinados pela Riegl, fabricante de sistema ALS FWF, considerando a emissão de pulsos LASER no comprimento de onda igual a 900 nm (WEHR e LOHR, 1999).

QUADRO 2.4 – REFLETIVIDADE DE MATERIAIS


MATERIAL	REFLETIVIDADE (%)
Madeira (pino, limpo e seco)	90
Neve	80 - 90
Alvenaria (branca)	85
Calcário, argila	75
Árvores caducifólias	60
Árvores coníferas	30
Carbonato seco	57
Carbonato molhado	41
Areia de praia e deserto	50
Madeira áspera limpa	25
Concreto plano	24
Asfalto com seixos	17
Lava vulcânica	8
Neoprene preto (borracha sintética)	5

FONTE: Wehr e Lohr (1999).

O Quadro 2.4 apresenta refletividade de 60% para as árvores caducifólias, também denominadas caducas ou decíduas, estas plantas perdem suas folhas geralmente no outono e inverno, meses mais frios e sem chuva. Árvores coníferas apresentam refletividade de 30% e possuem forma de cone, folhas verdes e pontiagudas que se mantêm durante as estações do ano.

A Figura 2.19 ilustra as assinaturas espectrais para estrada de asfalto, telhado de cerâmica, grama seca, solo exposto com calcário e água do mar, a partir de medidas realizadas com sistema ALS que emite feixe LASER com comprimento de onda igual a 1,064 μm .

FIGURA 2.19 – ASSINATURAS ESPECTRAIS



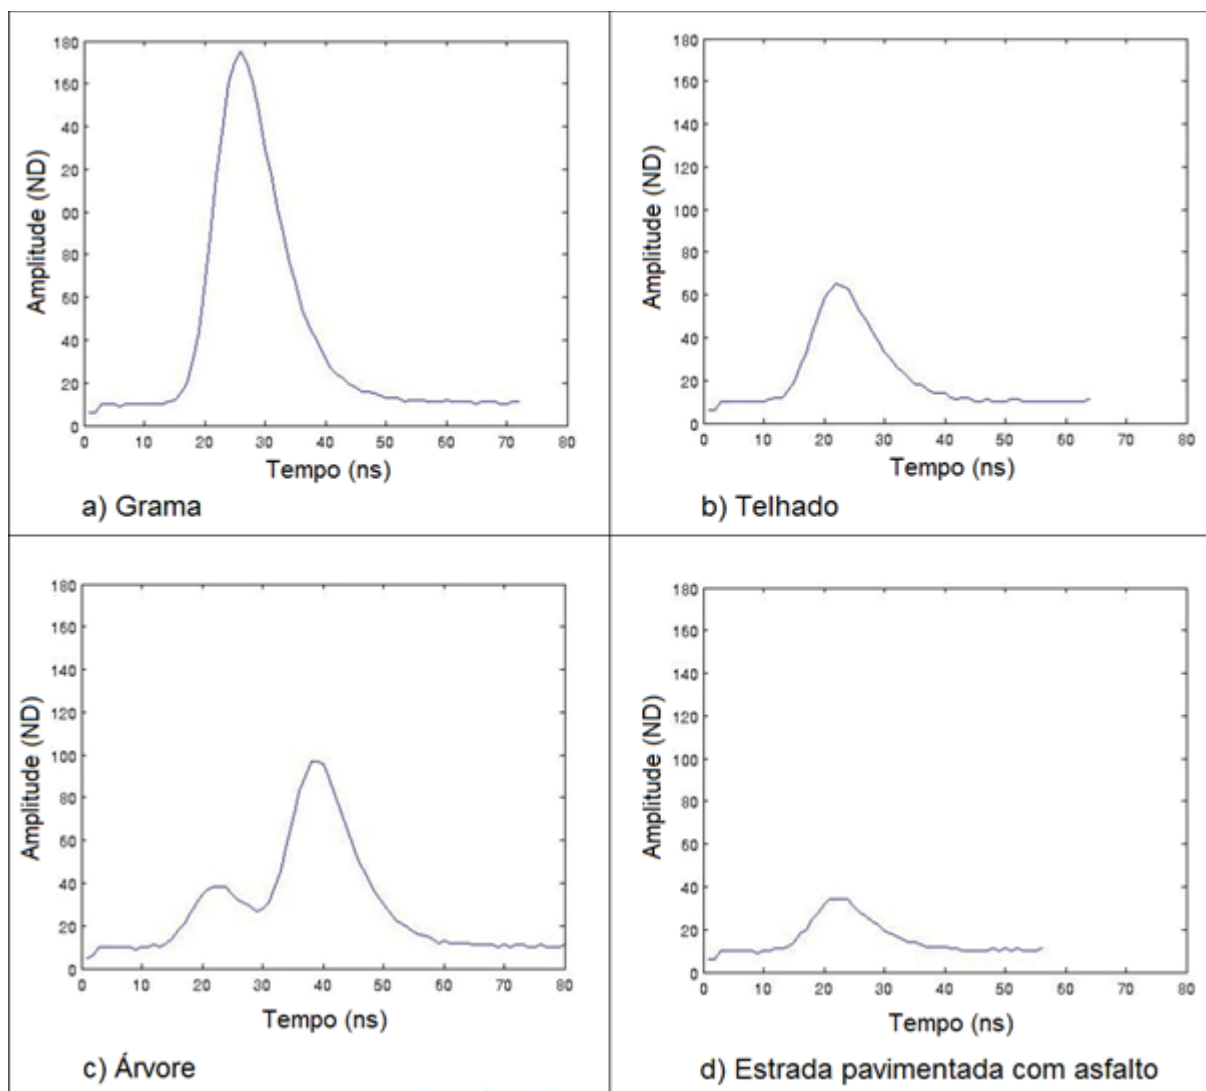
FONTE: Adaptado de Yan et al. (2015).

A melhor separação da Figura 2.19 ocorre na curva da grama seca, pois apresenta alta reflectância. A curva da resposta espectral da água do mar também está bem separada, mas por apresentar baixa reflectância. As curvas de solo exposto com calcário, telhado de cerâmica e estrada pavimentada com asfalto, apresentam boa separação, porém estão mais próximas e dependendo da área em que os dados foram medidos podem apresentar confusão na separação destas feições.

A assinatura espectral também pode ser representada através da WF do sinal de retorno do alvo que foi atingido pelo feixe LASER. Enquanto a reflexão causada por vegetação arbórea apresenta WF mais longa e com múltiplos picos, o retorno causado pela superfície de uma estrada asfaltada é caracterizado por um pico mais curto com baixo valor de amplitude (YAN et al., 2015).

Zaletnyik et al. (2010), em estudo sobre classificação de nuvem de pontos em área urbana, utilizaram como referência WFs características de alvos como árvore, grama seca, telhado de cerâmica e estrada pavimentada com asfalto, conforme ilustra a Figura 2.20. As WFs características foram geradas pela Optech, fabricante do sistema ALTM 3100 que mediu as WFs do referido estudo.

FIGURA 2.20 – WFS CARACTERÍSTICAS



FONTE: Adaptado de Zaletnyik et al. (2010).

2.9 ALTM PEGASUS HD500

As WFs utilizadas nesta tese foram medidas com o sistema ALTM Pegasus HD500 da Optech que é ilustrado na Figura 2.21. Este possibilita o registro discreto dos pontos medidos com o feixe LASER e também a completa digitalização da WF do sinal de retorno.


FIGURA 2.21 – SISTEMA ALTM PEGASUS HD500



FONTE: Optech (2014).

A Figura 2.22 ilustra o ponto de referência (PR) para as medidas realizadas com o sistema ALTM Pegasus HD500. O plano de referência é definido pelos eixos X (positivo na direção de voo) e Y (ortogonal ao eixo X, positivo no sentido horário), com origem no PR. O eixo Z é positivo na direção nadir, formando assim um sistema referencial de coordenadas tridimensional levógiro (OPTECH, 2012b).


FIGURA 2.22 – PONTO DE REFERÊNCIA DO ALTM PEGASUS HD500



FONTE: Optech (2012b).

A Figura 2.23 ilustra os pontos de origem dos sistemas referenciais de coordenadas do INS, receptor do sinal GNSS e o ponto de referência do sensor do sistema ALTM Pegasus HD500 instalado em uma aeronave.

FIGURA 2.23 – SISTEMAS REFERENCIAIS DO ALTM PEGASUS HD500



FONTE: Optech (2012b).

Especificações técnicas do sistema ALTM Pegasus HD500 são apresentadas no Quadro 2.5.

QUADRO 2.5 – ESPECIFICAÇÕES TÉCNICAS DO ALTM PEGASUS HD500

PARÂMETRO	ESPECIFICAÇÃO	OBSERVAÇÃO
Altura de operação	300 – 2.500 m	Nominal, para alvos com refletividade de 10 %. FOV de 50° e atmosfera padrão (atm).
Precisão horizontal	1/5.500 x altura de voo	1 σ , FOV de 50° com 1 atm.
Precisão vertical	5 – 15 cm	1 σ , FOV de 50° com 1 atm. Depende de parâmetros operacionais.
Frequência de operação	100 – 500 kHz	Programável.
Frequência de varredura efetiva	140 Hz	Programável.
Ângulo de visada (FOV)	65 °	Valor máximo programável.
Compensação em Roll mínimo	$\pm 5^\circ$	Programável.
Sistema de posicionamento e orientação	PosAV 510 (OEM)	72 canais com dupla frequência GPS/GNSS/Receptor banda L.
Separação mínima dos alvos	< 1,0 m	Para registro na forma discreta.
Medidas de distância	Acima de 4 retornos (discretos)	Para cada pulso emitido.
Divergência do feixe LASER	0,25 mrad (1/e)	
Classificação do LASER	1.064 nm	Classe IV (nocivo aos olhos).
Medida de intensidade	Acima de 4 medidas	Realizadas com 12 bits.
Gravação dos dados	HD externo com entrada SSD	
Potência	28 V (contínua); 600 W (nominal); 21 A	
Dimensões do sensor LASER	630 x 540 x 450 mm	
Peso do sistema	49 kg	

FONTE: Optech (2014).

Para as especificações do Quadro 2.5 deve-se levar em consideração que a superfície do alvo tenha refletividade de pelo menos 10 % e área maior que o tamanho do footprint do feixe LASER, FOV superior a 50° em atmosfera padrão e ângulo máximo de incidência do feixe LASER de 25°. A precisão horizontal nominal para alturas de voo iguais a 1.000 m, 2.000 m e 2.500 m são apresentadas no Quadro 2.6.

QUADRO 2.6 – PRECISÃO PLANIMÉTRICA


ALTURA DE VOO (m)	PRECISÃO PLANIMÉTRICA (m)
1.000	0,18
2.000	0,36
2.500	0,45

FONTE: O Autor (2018).

Devido ao ALTM Pegasus HD500 apresentar alta frequência de operação, quando é utilizado o modo de emissão de múltiplos pulsos existe uma faixa de

operação que não pode ser utilizada para a aquisição dos dados. Esta faixa é denominada “área cega” e é ilustrada na Figura 2.24.

FIGURA 2.24 – FAIXAS DE OPERAÇÃO DO ALTM PEGASUS HD500



FONTE: Optech (2012b).

O ALTM Pegasus HD500 utiliza um espelho oscilante para o direcionamento do pulso LASER emitido. Com isto, a varredura é realizada transversalmente à direção da linha de voo da aeronave durante o aerolevantamento, gerando uma varredura em padrão “zig-zag” (PIROTTI et al., 2013).

O cálculo da distância (d) entre o alvo e o sensor do sistema ALTM Pegasus HD500 é realizado através da Equação (2.25), que utiliza a velocidade de propagação do pulso LASER e o tempo de percurso entre a emissão e recepção. O pulso deste sistema é emitido na velocidade da luz (c), com comprimento de onda igual a 1.064 nanômetros (nm). No entanto, esta velocidade depende do meio em que o pulso foi emitido, sendo então utilizado o índice de propagação (n), que é função da temperatura (T) e pressão (P). Através da Equação (2.24) o índice (n) pode ser calculado (OPTECH, 2012a).

$$n = 1 + 78,7 \times \frac{P}{273,15+T} \times 10^{-6} \quad (2.24)$$

Os valores médios de temperatura são expressos em graus Celsius ($^{\circ}\text{C}$) e a pressão atmosférica em hectopascals (hPa). Se os parâmetros (T) e (P) são conhecidos no ar e solo, deve ser utilizada a média destes valores. Quando estes valores são conhecidos apenas no solo, pode ser realizada a aproximação de que a temperatura e a pressão diminuem, respectivamente, $6,5^{\circ}\text{C}$ e 111 hectopascals por quilômetro (OPTECH, 2012a).

$$d = \frac{c \times \Delta t}{2 \times n} = \frac{2,99792458 \times 10^8 \times \Delta t}{2 \times \left(1 + 78,7 \times \frac{P}{273,15 + T} \times 10^{-6}\right)} \quad (2.25)$$

O tempo de percurso (Δt) do pulso LASER da Equação (2.25) é calculado através da Equação (2.26).

$$\Delta t = T_1 + (t_i - t_0) \quad (2.26)$$

O parâmetro (T_1) da Equação (2.26) é disponibilizado no arquivo ASCII com as amostras de WF registradas pelo Digitizer. Os parâmetros (t_0) e (t_i) são os tempos dos picos detectados nas WFs do pulso LASER emitido e sinal de retorno.

2.10 DIGITIZER

A digitalização da WF do sinal de retorno para cada pulso LASER emitido com o sistema ALTM Pegasus HD500 é realizada no Intelligent Waveform Digitizer (IWD), ilustrado com a Figura 2.25. Na segunda versão, o IWD digitaliza a amplitude do sinal de retorno com 12 bits, o que corresponde a 4.096 níveis digitais (ND). Realiza o registro dos sinais com taxa de amostragem de 1 ns, duração máxima da WF do pulso emitido (t_0) de 40 ns e do sinal recebido (t_i) de 499 ns. Os valores das amplitudes apresentam o offset de 200 ND (OPTECH, 2012b).

FIGURA 2.25 – INTELLIGENT WAVEFORM DIGITIZER



FONTE: Optech (2012a).

Especificações técnicas do IWD são apresentadas no Quadro 2.7.

QUADRO 2.7 – ESPECIFICAÇÕES TÉCNICAS DO IWD

PARÂMETRO	ESPECIFICAÇÃO
Resolução radiométrica da digitalização:	12 bits
Intervalo amostral:	1 ns
Taxa de aquisição dos dados:	Acima de 100 kHz
Duração máxima do pulso:	
Emitido (t_0):	40 ns
Retorno (t_1):	499 ns
Alimentação:	0 – 1 V
Gravação dos dados:	HD externo com entrada SSD
Potência:	< 200 W
Temperatura de operação:	0 – 35°
Umidade relativa:	0 – 95° sem condensação

FONTE: Optech (2012b).

No processamento de cada WF digitalizada com o IWD devem ser levadas em consideração as seguintes observações (OPTECH, 2012a):

- Os valores de amplitude digitalizados na WF são relativos ao pulso emitido e podem ser afetados por fatores como a distância do alvo, reflectância da seção atingida, comprimento de onda do feixe LASER, além da atenuação atmosférica;
- Os valores de amplitudes digitalizados são relativos ao offset de 200 ND e esta é a referência para as amplitudes mínimas;
- A digitalização da WF do sinal de retorno é amplificada, com isto o valor de amplitude digitalizado do pulso LASER emitido apresenta fator de escala diferente, porém este é correlacionado à amplitude do pico detectado na WF;
- No caso de não ser detectado sinal de retorno (t_i) para o pulso LASER emitido (t_0), são registrados zeros em todos os bytes da WF digitalizada. Sempre que o pulso LASER for emitido, a WF para (t_0) é registrada;
- As distâncias calculadas com as WFs podem ser um pouco diferentes das distâncias obtidas diretamente com o sistema ALTM Pegasus HD500. Estas são relativas ao espelho do sistema de varredura LASER, enquanto a WF é a digitalização do sinal de retorno no receptor do IWD. A diferença dos caminhos percorridos e atrasos na transmissão do sinal causam este efeito. Com isto, tem-se também uma constante para transformar o tempo detectado com o pico da WF em distância.


A interface do IWD é realizada através dos softwares Digitizer Data Acquisition and Recording (DDAR) e Digitizer Data Retrieval (DDR). O primeiro possibilita a criação de novos arquivos, gravação de um número específico de cenas, salvar o arquivo no formato “.df2” para visualização no sistema operacional Windows. O software DDR possibilita a visualização das WFs digitalizadas e os picos que foram utilizados no cálculo da distância para os retornos detectados (OPTECH, 2012a).

Quando o IWD é utilizado na amostragem da WF do pulso emitido e do sinal de retorno, a determinação do tempo de percurso é realizada no software DDR com algoritmo da Optech. Este decompõe os retornos contidos na WF que pode ser simples ou complexa. Uma WF complexa apresenta retornos com sobreposição das

curvas que definem os picos. O software DDR também possibilita a visualização das posições dos picos contidos na WF, incluindo o pico do pulso emitido. A distância de cada pulso é calculada através do intervalo de tempo entre o pulso emitido (t_0) e o recebido (t_i), somado ao tempo (T_1) determinado para cada retorno (OPTECH, 2012a).

A Figura 2.26 ilustra três retornos detectados pelo software DDR em uma WF complexa. Os tempos destes retornos foram 30, 79 e 115 ns e estão indicados com as retas verticais vermelhas, os valores de amplitudes foram de 87 ND, 271 ND e 150 ND. O pulso LASER emitido (t_0) corresponde a uma WF simples, com um pico bem definido na curva no tempo igual a 20 ns e amplitude igual a 600 ND.

FIGURA 2.26 – WF COMPLEXA COM 3 RETORNOS DETECTADOS




FONTE: O Autor (2018).

O tempo registrado para o sinal de retorno (T_1) é representado com a reta vertical amarela na Figura 2.26. A este é somado o tempo detectado no pico da WF, com isto é possível determinar a distância entre o sensor e o alvo através da Equação (2.25). Os tempos são apresentados no eixo das abscissas em nano segundos (ns), sendo também indicadas algumas distâncias em metros (m). No eixo das ordenadas são apresentados os valores de amplitude em níveis digitais (ND).

Na WF da Figura 2.26 poderia ser detectado pelo menos mais um pico, no tempo igual a 96 ns, além dos detectado no software DDR, pois antes do último pico há uma sobreposição. A Figura 2.27 ilustra outra WF complexa com quatro retornos determinados no software DDR em que também poderia ser detectado mais um pico no tempo de 68 ns.

FIGURA 2.27 – WF COMPLEXA COM 4 RETORNOS DETECTADOS



FONTE: O Autor (2018).

O software DDR foi desenvolvido para visualização das WFs e análise da nuvem de pontos gerada quando o IWD foi utilizado na digitalização. Neste software não é possível extrair as amostras dos segmentos das WFs. Esta etapa deve ser realizada no software Lidar Mapping Suite (LMS) da Optech. Os dados do arquivo ASCII com as amostras de amplitude da WF do pulso LASER emitido (0), e do sinal de retorno (1), digitalizadas pelo IWD são ilustradas no Quadro 2.8.


QUADRO 2.8 – AMOSTRAS DE AMPLITUDE DA WF

TGPS (s)	CÓDIGO: EMIÇÃO (T_0) / RETORNO (T_1)	TEMPO DE RETORNO (ns)	AMOSTRAS DE AMPLITUDE (ND)
491434,525083	0	0,00	[219 214 208 203 199 196 193 195 197 198 200 203 214 239 284 349 429 511 582 632 651 640 605 553 494 434 379 332 295 266 241 223 211 202 194 189 186 184 184 185 188 193 197 199 201 204 206 209]
491434,525083	1	5.295,96	[201 199 200 200 201 203 205 208 212 215 214 212 209 206 204 203 204 204 202 199 204 230 286 386 541 752 1000 1259 1490 1656 1735 1719 1617 1458 1271 1082 907 757 634 538 463 399 348 308 278 254 236 222 213 207 205 210 224 247 280 316 351 379 397 401 393 374 350 323 295 270 247 229 215 204 198 195 196 198 200 200 200 199 198 196 195 193 190 187 185 186 186 192]

FONTE: O Autor (2018).

A Figura 2.28 ilustra a determinação do tempo de percurso utilizando os picos detectados na WF do pulso emitido e do sinal de retorno. A detecção foi realizada através do método de SDP com PML, pois a WF do sinal de retorno é simples com picos bem definidos.

FIGURA 2.28 – TEMPO DE PERCURSO EM WF SIMPLES



FONTE: O Autor (2018).

Na Figura 2.28 o valor do parâmetro (T_1) é igual a 5.295,96 ns e foi obtido diretamente no arquivo ASCII. Os tempos dos picos contidos na WF do sinal de retorno, parâmetros (t_i), apresentam os valores de 31 ns e 60 ns, correspondentes ao primeiro (t_1) e segundo (t_2) retornos. O tempo do pico na WF do pulso emitido (t_0) é de 21 ns. Subtraindo o valor do tempo do pico na WF do pulso LASER emitido ($t_0 = 21$ ns) do tempo do primeiro pico na WF do sinal de retorno ($t_1 = 31$ ns), tem-se o tempo do primeiro retorno de 10 ns. Da mesma forma, fazendo a subtração do tempo do segundo pico na WF do sinal de retorno ($t_2 = 60$ ns), encontra-se o tempo do segundo retorno de 39 ns. Considerando os valores de temperatura e pressão no terreno iguais a 22°C e 1.017 hPa, para a altura de voo de 800 m, estes correspondem a 16,8°C e 928,2 hPa, respectivamente. Aplicando-se estes valores na Equação (2.25), calculou-se a distância para os dois retornos, sendo os valores encontrados iguais a 795,497 m e 799,845 m. A Tabela 2.1 apresenta a diferença das distâncias calculadas no software DDR e através do método de SDP na WF.

TABELA 2.1 – COMPARAÇÃO DAS DISTÂNCIAS CALCULADAS

RETORNO	DISTÂNCIAS (m)		DIFERENÇAS (m)
	DDR	WF	
1	795,377	795,497	-0,120
2	799,712	799,845	-0,133


FONTE: O Autor (2018).

Na Tabela 2.1 as distâncias calculadas com os picos na WF digitalizada são compatíveis com as distâncias obtidas no software DDR e estão dentro da precisão na medida de distância. Estas distâncias dependem do método de detecção de picos utilizado e do atraso causado pela digitalização da WF no IWD, conforme a precisão nas medidas de distância com a tecnologia LIDAR, diferenças de 1 ns nesta etapa correspondem a 0,15 m.

2.11 GEORREFERENCIAMENTO

Sistemas ALS apresentam duas unidades principais. A primeira é a unidade de navegação da aeronave, composta pelo sistema inercial (INS) que proporciona a atitude e o receptor do sistema de posicionamento global (GNSS). A segunda é a unidade LASER (UL) que realiza a medida de distância entre o sensor e a superfície iluminada pelo feixe LASER (FL). O georreferenciamento é feito através de rotações e translações entre os sistemas de coordenadas envolvidos, após este processo as medidas são referenciadas ao sistema geodésico adotado no mapeamento, conforme ilustra a Figura 2.29 (FILIN, 2003).


FIGURA 2.29 – SISTEMAS REFERENCIAIS DE COORDENADAS EM ALS



FONTE: Adaptado de HABIB et al. (2008).

As coordenadas da trajetória da aeronave, determinadas com o receptor GNSS, estão referenciadas ao sistema geodésico. O sistema inercial (INS) determina a atitude da aeronave através dos ângulos de Euler (roll, pitch e yaw), estes correspondem a rotações nos eixos X, Y e Z, conforme ilustra a Figura 2.30. A Figura 2.30a ilustra os ângulos de Euler, ângulo de emissão (α) do feixe LASER, distância (d) e as coordenadas (Y_{UL} , Z_{UL}) do ponto (P) no sistema referencial de coordenadas da UL. A Figura 2.30b ilustra que os sistemas referenciais de coordenadas do INS e da UL não estão alinhados.

FIGURA 2.30 – SISTEMAS REFERENCIAIS DE COORDENADAS DO INS E UL



FONTE: Adaptado de SHAN e TOTH (2009).

O georreferenciamento dos pontos é realizado através da Equação (2.27), que em notação matricial relaciona os sistemas envolvidos através de translações e rotações (HABIB et al., 2008).

$$\vec{X}_G = \vec{X}_0 + R_{yaw, pitch, roll} \cdot \vec{P}_G + R_{yaw, pitch, roll} \cdot R_{\Delta\omega, \Delta\varphi, \Delta\kappa} \cdot R_{\alpha, \beta} \cdot \begin{bmatrix} 0 \\ 0 \\ -\rho \end{bmatrix} \quad (2.27)$$

Onde:

\vec{X}_G – Vetor com as coordenadas cartesianas dos pontos no sistema geodésico de referência;

\vec{X}_0 – Vetor com as coordenadas da origem do sistema INS/GNSS referenciadas ao sistema geodésico de referência;

$R_{yaw, pitch, roll}$ – Matriz de rotação entre o sistema de coordenadas do INS/GNSS e o sistema geodésico de referência;

\vec{P}_G – Vetor de translação entre a origem do sistema de coordenadas do INS/GNSS e a origem do sistema de coordenadas da unidade LASER. Também são denominados de parâmetros “lever-arm” e são determinados através de medidas realizadas com uma estação total sobre os pontos de referência dos sistemas, devidamente instalados na aeronave em processo de calibração;

$R_{\Delta\omega, \Delta\varphi, \Delta\kappa}$ – Matriz de rotação entre o sistema de coordenadas do INS/GNSS e o sistema de coordenadas da unidade LASER. Esta matriz modela a inclinação de montagem do sistema ALS em relação ao sistema INS/GNSS;

$R_{\alpha, \beta}$ - Matriz de rotação entre o sistema de coordenadas da unidade LASER e o sistema de coordenadas do feixe LASER. Em que “ α ” e “ β ” são os ângulos de varredura. Quando a varredura é realizada por um sistema de espelho oscilante, o parâmetro “ β ” é nulo;

ρ - É a distância entre a origem do sistema de coordenadas do feixe LASER e o ponto “P” na superfície medida.

Com a matriz de rotação ($R_{yaw, pitch, roll}$) é realizada uma transformação ortogonal tridimensional conforme. Os pontos referenciados ao sistema de coordenadas da unidade LASER são rotacionados para um sistema paralelo ao sistema geodésico de referência, a partir da rotação dos ângulos determinados com o sistema INS na ordem apresentada na Equação (2.28), respectivamente rotações em torno dos eixos Z (k), Y(ω) e X (φ). Nas Equações (2.29), (2.30) e (2.31) são apresentadas as matrizes dos cossenos diretores em relação a cada eixo do sistema referencial do INS (SHAN e TOTH, 2009).

$$R_{yaw, pitch, roll} = R_k \cdot R_\varphi \cdot R_\omega \quad (2.28)$$

$$R_\omega = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\omega) & -\text{sen}(\omega) \\ 0 & \text{sen}(\omega) & \cos(\omega) \end{bmatrix} \quad (2.29)$$

$$R_\varphi = \begin{bmatrix} \cos(\varphi) & 0 & \text{sen}(\varphi) \\ 0 & 1 & 0 \\ -\text{sen}(\varphi) & 0 & \cos(\varphi) \end{bmatrix} \quad (2.30)$$

$$R_k = \begin{bmatrix} \cos(k) & -\text{sen}(k) & 0 \\ \text{sen}(k) & \cos(k) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (2.31)$$

Os elementos da matriz de rotação são apresentados na Equação (2.32).

$$R_k \cdot R_\varphi \cdot R_\omega = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \quad (2.32)$$

$$R_k \cdot R_\varphi \cdot R_\omega = \begin{bmatrix} \cos(k) & -\sin(k) & 0 \\ \sin(k) & \cos(k) & 0 \\ 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \cos(\varphi) & 0 & \sin(\varphi) \\ 0 & 1 & 0 \\ -\sin(\varphi) & 0 & \cos(\varphi) \end{bmatrix} \cdot \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\omega) & -\sin(\omega) \\ 0 & \sin(\omega) & \cos(\omega) \end{bmatrix}$$

Onde:

$$r_{11} = \cos(\varphi) \cos(k)$$

$$r_{12} = -\cos(\omega) \sin(k) + \sin(\omega) \sin(\varphi) \cos(k)$$

$$r_{13} = \sin(\omega) \sin(k) + \cos(\omega) \sin(\varphi) \cos(k)$$

$$r_{21} = \cos(\varphi) \sin(k)$$

$$r_{22} = \cos(\omega) \cos(k) + \sin(\omega) \sin(\varphi) \sin(k)$$

$$r_{23} = -\sin(\omega) \cos(k) + \cos(\omega) \sin(\varphi) \sin(k)$$

$$r_{31} = -\sin(\varphi)$$

$$r_{32} = \sin(\omega) \cos(\varphi)$$

$$r_{33} = \cos(\omega) \cos(\varphi)$$

Maiores detalhes sobre os sistemas referenciais de coordenadas e princípios físicos envolvidos no georreferenciamento dos pontos medidos com sistemas ALS podem ser vistos em Shan e Toth (2009).

2.12 ALGORITMOS GENÉTICOS

A criação dos computadores foi uma revolução para a história humana, permitiu o desenvolvimento do conhecimento a partir do estudo e predição de fenômenos naturais. Esta inovação foi baseada na capacidade humana de aprender e se adaptar, pelo interesse em biologia, psicologia e eletrônica. Entre 1950 e 1960, a evolução da biologia motivou os cientistas da computação a desenvolverem seus estudos e foram criadas as técnicas de Redes Neurais Artificiais (Artificial Neural Networks), Aprendizado de Máquina (Machine Learning) e Computação Evolucionária (Evolutionary Computation). Os Algoritmos Genéticos (Genetic Algorithms) estão incluídos na Computação Evolucionária, foram publicados em 1975 no livro “Adaptation in Natural and Artificial Systems” de John Holland, como uma abstração da evolução biológica (MITCHELL, 1996).

De acordo com Goldberg (1989), John Holland foi o primeiro pesquisador a desenvolver um algoritmo com base na teoria da evolução das espécies de Charles Darwin (1859) e avanços das pesquisas biológicas nos processos genéticos dos organismos. A teoria Darwiniana foi apresentada em 1858 para a Linnean Society of London e publicada em 1859 no livro “On the Origin of Species by Means of Natural Selection, or the Preservation of Favoured Races in the Struggle for Life”.

Algoritmos Genéticos (AG) foram inspirados na adaptação de um organismo que busca a sobrevivência e reprodução da sua espécie no meio ambiente. Utilizam processos do Neodarwinismo como a seleção, cruzamento, mutação e competição. Sendo a expansão das populações de diferentes espécies limitadas pelo espaço finito (MITCHELL, 1996).

Para ser diferenciado de outros métodos computacionais um AG deve apresentar os seguintes elementos: população inicial de cromossomos; seleção artificial de acordo com a aptidão (fitness); cruzamento para a produção da nova geração; e mutação genética aleatória da nova geração. Os cromossomos utilizados em AG são uma cadeia binária de genes, onde a localização (*locus*) no cromossomo apresenta dois alelos com valor 0 ou 1. Cada cromossomo é um ponto no espaço de busca de soluções possíveis. AG possibilitam a mudança do cromossomo de uma população para outra visando à solução do problema. A avaliação da solução é realizada através do valor de aptidão, sendo este o limiar estabelecido para determinar o fim do processo (MITCHELL, 1996).

Segundo Negnevitsky (2005), a solução ótima de um problema com AG é um processo em que cada uma das iterações é chamada de geração, sendo utilizados os dez passos descritos a seguir:

- 1) Representar o domínio da variável do problema como um cromossomo. Definindo o seu comprimento, tamanho da população inicial de cromossomos, a probabilidade de cruzamento e a probabilidade de mutação;
- 2) Definir a função de aptidão para medir o desempenho de cada cromossomo no domínio do problema. Esta função é utilizada para a seleção dos cromossomos durante a reprodução;
- 3) Gerar a população inicial de cromossomos de forma aleatória;
- 4) Calcular a aptidão de cada cromossomo;
- 5) Selecionar os pares de cromossomos para a reprodução. Os cromossomos pais são selecionados de acordo com a probabilidade relacionada com a aptidão. Cromossomos com alta aptidão apresentam alta probabilidade de serem selecionados para o cruzamento;
- 6) Criar um par de cromossomos filhos aplicando os operadores genéticos de cruzamento e mutação;
- 7) Colocar os cromossomos filhos na nova geração;
- 8) Repetir o passo (5) até que o tamanho da nova geração seja igual ao tamanho da população inicial;
- 9) Substituir a população inicial de cromossomos (pais) pela nova geração;
- 10) Retornar ao passo (4) e repetir o processo até que seja satisfeito o critério de término.

O uso de AG pressupõe a existência de um problema que seja necessário otimizar, por exemplo uma função com parâmetros a serem determinados. Isto implica na definição do espaço das possíveis soluções, dado pela quantidade de parâmetros (incógnitas) e a faixa de variação de cada um deles. Cada solução possível consiste em um conjunto de valores prováveis para os parâmetros, sendo utilizadas regras de transição probabilísticas (GOLDBERG, 1989).

O passo (1) consiste em produzir uma série de soluções arbitrárias para o problema, sendo cada uma delas composta pelo conjunto de incógnitas que se procura. A seguir, estas soluções devem ser representadas na forma de uma cadeia binária. Para isto, os valores das incógnitas são transformados para a forma binária.

Posteriormente as séries binárias são concatenadas para formar uma cadeia maior que é o cromossomo do problema.

Supondo que um determinado problema tenha três incógnitas (I_1 , I_2 , I_3) e que uma solução provável seja (12, 10, 7) deve-se representar esta solução como uma série binária. Adotando 4 bits para representar cada incógnita, os valores passam a ser $I_1 = [1\ 1\ 0\ 0]$, $I_2 = [1\ 0\ 1\ 0]$ e $I_3 = [0\ 1\ 1\ 1]$. A solução do problema, composta por 12 genes com representação binária, é o cromossomo artificial ilustrado na Figura 2.31.

FIGURA 2.31 – CROMOSSOMO COM 12 GENES

1	1	0	0	1	0	1	0	0	1	1	1
---	---	---	---	---	---	---	---	---	---	---	---

FONTE: Adaptado de Negnevitsky (2005).

A solução do problema também implica na proposta de uma função objetivo que se deseja minimizar ou maximizar. Para isto, é necessário propor um parâmetro para medir quanto à solução encontrada satisfaz o problema. Isto pode ser feito comparando o resultado obtido aplicando os valores das incógnitas determinadas nos AG com a solução esperada, previamente conhecida. Com isto, é possível medir o grau de aptidão de cada cadeia binária ao problema e encontrar as melhores ou piores soluções que servem de base para selecionar a mais adequada ao problema, como foi descrito no passo (5).

O conjunto inicial de possíveis soluções (primeira geração) pode ser posteriormente ordenado de forma decrescente em função da sua aptidão. Assim, o primeiro elemento seria aquele mais apto para a solução do problema e o último o menos apto. Com base nos valores da aptidão um conjunto de soluções, as melhores, é preservado e o restante é descartado. Para isto, é necessário fixar um limiar de aptidão. As soluções preservadas são utilizadas para gerar novas soluções e preencher a lacuna deixada pelas que foram descartadas. Isto consiste em efetuar o cruzamento das melhores soluções na esperança de que duas boas soluções produzam uma solução ainda melhor.

Para combinar duas soluções, primeiro devem ser selecionadas as soluções a serem combinadas. As técnicas artificiais de seleção mais utilizadas em AG são a roleta, torneio e elitismo. Os parâmetros utilizados são os tamanhos máximos da

população, cromossomo, vetores dos indivíduos da população atual e nova, além do valor da aptidão (GOLDBERG, 1989).

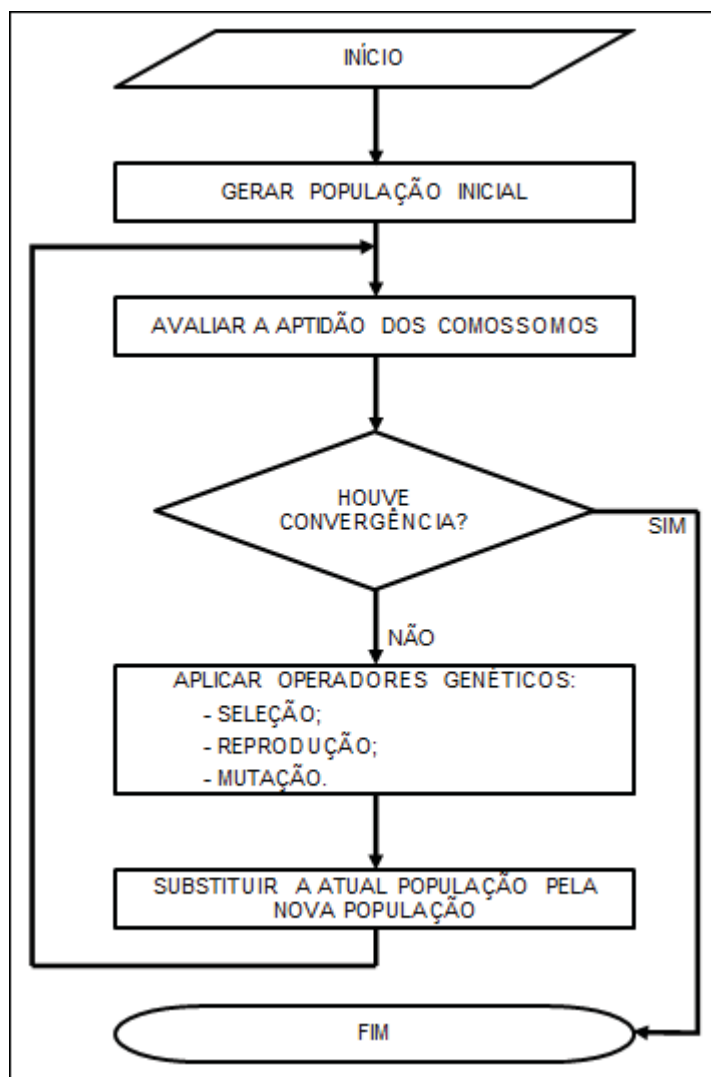
Para a seleção dos cromossomos a técnica da roleta é uma das mais utilizadas com objetivo de aumentar a aptidão da população. As porcentagens de aptidão dos cromossomos são representadas como áreas na superfície da roleta. Para selecionar um cromossomo, um número é gerado de forma aleatória dentro do intervalo entre 0 e 100. Este número corresponderá ao cromossomo selecionado. Com dois cromossomos selecionados é realizada a operação genética de reprodução (GOLDBERG, 1989).

O operador de reprodução procura aleatoriamente o ponto de quebra entre dois cromossomos pais e então troca partes destes cromossomos após este ponto. Como resultado dois novos cromossomos são gerados. Se não houver reprodução, então cromossomos clone são criados e a nova geração será uma cópia dos pais (NEGNEVITSKY, 2005).

A mutação é a mudança do gene através da introdução de material genético em um indivíduo de forma aleatória e raramente ocorre na natureza. Holland (1975) incluiu o operador de mutação para garantir a abertura do espaço de busca, tendo em vista que se o algoritmo passar da solução ótima a sequência de operações de seleção e reprodução chega a um conjunto de soluções homogêneas. Nestas condições os cromossomos seriam idênticos e a aptidão não poderia ser melhorada. Com a mutação evita-se a perda da diversidade genética e melhora-se a aptidão da população após algumas gerações, normalmente centenas. O operador de mutação troca genes do cromossomo aleatoriamente (NEGNEVITSKY, 2005).

Convencionalmente é utilizado o número de gerações previamente definidas como critério de parada do AG. Também pode ser utilizado o valor de aptidão como critério de parada. Na seleção natural, apenas as espécies com maior aptidão sobrevivem e passam seus genes para as novas gerações na reprodução. Processo semelhante ocorre nos AG, permanecendo inalterado o tamanho da população de cromossomos (NEGNEVITSKY, 2005). A Figura 2.32 ilustra o fluxograma dos AG.

FIGURA 2.32 – FLUXOGRAMA DOS ALGORÍTIMOS GENÉTICOS




FONTE: Adaptado de Negnevitski (2005).

2.13 LÓGICA FUZZY

A Lógica Fuzzy, também denominada lógica nebulosa, possibilita a modelagem de dados em processos que exigem tomadas de decisão com certo grau de incerteza. É uma contraposição à decisão tomada utilizando limiares bem definidos, nítidos ou rígidos (crisp). Esta lógica foi desenvolvida a partir do conceito de conjuntos Fuzzy, descrito em 1965 no artigo “Fuzzy Sets” do professor Lotfi Zadeh do departamento de Engenharia Elétrica da Universidade da Califórnia. O conjunto Fuzzy aceita graus de pertinência, é contínuo e varia de zero a um. Operações lógicas de união, interseção, complemento e contingência são exemplos das operações que podem ser executadas sobre o conjunto Fuzzy (ZADEH, 1965).

Tradicionalmente os conjuntos booleanos são aplicados em questões de lógica, porém conforme ilustrado na Figura 2.33a, estes são binários ao contrário dos conjuntos Fuzzy que podem receber uma faixa de valores reais entre zero e um, conforme ilustrado na Figura 2.33b. A Lógica Fuzzy é multivalorada, trabalha com graus de pertinência dos valores lógicos entre 0 (completamente falso) e 1 (completamente verdadeiro), utiliza o raciocínio e a validade dos argumentos (NEGNEVITSKY, 2005).

FIGURA 2.33 – VALORES UTILIZADOS EM LÓGICA BOOLEANA E FUZZY



Fonte: Negnevitsky (2005).

Aplicando regras de inferência do tipo SE-ENTÃO (IF-THEN) a Lógica Fuzzy é uma forma de tratar a incerteza inerente a vários tipos de problemas. Funções Fuzzy são utilizadas para representar o grau de pertinência de algumas características através de uma inferência feita por regras. Apresenta desvantagens como a dificuldade na determinação da função de pertinência (CHENG et al., 2001).

Inferência é o processo que utiliza a teoria de conjuntos Fuzzy para obter as saídas esperadas a partir de variáveis de entrada. Os métodos de inferência mais conhecidos são o Mamdani e o Sugeno. O método Mamdani é o mais utilizado, sua

implementação apresenta as quatro etapas descritas a seguir (NEGNEVITSKY, 2005):

- 1) Nebulização das variáveis de entrada: o problema deve ser analisado e os dados de entrada devem ser transformados em variáveis linguísticas;
- 2) Avaliação das regras de inferência: as regras devem ser avaliadas através da associação das variáveis;
- 3) Agregação das variáveis de saída: as consequentes das regras definidas;
- 4) Desnebulização: os valores Fuzzy devem ser convertidos em números reais tendo assim valores de saída “crisp”. A desnebulização pode ser realizada de diversas formas, sendo o método do centroide o mais conhecido.

O centroide corresponde ao centro de gravidade (CG) dos polígonos e pode ser calculado através da Equação (2.33). Na Lógica Fuzzy, um conjunto “A” com universo “X” contido no intervalo “a, b” $[0, 1]$ é definido pela função $\mu_A(x)$. Esta função apresenta valor igual a 1 quando “x” pertence completamente ao conjunto “A”, valor 0 quando “x” não pertence ao conjunto “A”, e o valor entre 0 e 1, se “x” pertence parcialmente ao conjunto “A” (NEGNEVITSKY, 2005).

$$CG = \frac{\sum_{x=a}^b \mu_A(x) \cdot x}{\sum_{x=a}^b \mu_A(x)} \quad (2.33)$$

2.14 ESTADO DA ARTE

De acordo com BLAIR et al. (1999), a partir do sistema LVIS observou-se o potencial de sistemas ALS FWF no mapeamento e modelagem das áreas de drenagem em bacias hidrográficas, isto impulsionou o desenvolvimento de metodologias para a extração das informações contidas na WF.

Harsdorf e Reuter (2000), com objetivo de avaliar as distâncias determinadas sem aplicar filtros para reduzir ruídos no domínio da frequência, utilizaram sinal LASER simulado para distâncias curtas e o algoritmo iterativo de Richardson-Lucy. Afirmam que a reconstrução do sinal sem ruídos foi melhor com a metodologia ao ser comparado com métodos de deconvolução utilizando a transformada de Fourier ou Mínimos Quadrados Não Negativos.

Wagner et al. (2004) realizaram testes com as funções de limiar, centro de gravidade, ponto de máximo local, cruzamento com o zero da segunda derivada e com o método da constante de fracionamento para a simples detecção de picos em WF. A partir dos parâmetros destas funções realizaram a pré-classificação dos dados considerando a potência e forma do sinal de retorno, além da área atingida na superfície que causou o retroespalhamento. De acordo com os autores a interpretação das feições pode ser realizada com maior controle utilizando funções analíticas adequadas. Relatam também que o pulso que atinge um telhado com inclinação de 45% e footprint de 1 m de diâmetro pode apresentar variações na medida de distância de até 40 cm, dependendo da função utilizada na detecção do pulso contido no sinal de retorno.

Jutzi e Stilla (2006) demonstraram que quando o feixe LASER intercepta superfícies planas inclinadas, a WF digitalizada do sinal de retorno apresenta característica de assimetria. Isto auxilia na classificação dos pontos em telhados ou superfícies pavimentadas. Realizaram a deconvolução da WF transformando-a para o domínio de Fourier, aplicaram o filtro de Wiener e definiram a função que representa a WF da superfície iluminada.

Ducic et al. (2006) realizaram a classificação de WFs com algoritmo de classificação não supervisionada. Utilizando as informações de amplitude, duração do pulso e número de retornos, conseguiram classificar os pontos em vegetação e não vegetação. A classificação obteve acurácia global de 88,6 % e coeficiente kappa

de 0,8, estes parâmetros foram calculados utilizando 500 amostras distribuídas aleatoriamente na área do estudo.

Wagner et al. (2006) utilizaram alvos de referência para calibrar a amplitude dos dados provenientes do sistema ALS Riegl LMS-Q560. Na decomposição da WF em séries de Gaussianas com os parâmetros de distância, amplitude e duração de cada pulso contido da WF, estimaram a seção de retroespalhamento para diferentes tipos de alvos.

Nordin (2006) aplicou a deconvolução da WF com o algoritmo Richardson-Lucy para aumentar a quantidade de pontos detectados em copas de árvores e no terreno. Utilizou WFs medidas com o sistema TopEye Mark II, e os melhores resultados foram obtidos em áreas com vegetação arbórea, onde houve aumento de 75 % nos pontos determinados.

Mallet et al. (2008) realizaram a classificação supervisionada de WFs medidas em áreas urbanas com o sistema Riegl LMS-Q560, em feições de edificações, vegetação, solo exposto e estrada pavimentada, atingiram acurácia global de 92 %. Para isto utilizaram parâmetros obtidos na decomposição da WF com a função Gaussiana Generalizada e Support Vector Machines.

Roncat et al. (2008) utilizando o método denominado “Averaged Square Difference Function”, equivalente a correlação do sinal emitido e recebido, conseguiram detectar os retornos e suprimir picos causados pelo ringing effect nas WFs medidas com o sistema Riegl LMS-Q560.

Mallet et al. (2009) reconstruíram WFs através do algoritmo Reversible Jump Markov Chain Monte Carlo, este utiliza as funções Gaussiana Generalizada, Weibull, Nakagami e Burr, de forma alterada para melhorar a modelagem. Realizaram testes com WFs de dados simulados e reais, com isto identificaram a limitação do número de picos contidos na WF, pois os primeiros retornos detectados contêm 90 % da energia do sinal refletido e mesmo para áreas de florestas, a WF atinge no máximo sete retornos, sendo comum apresentarem quatro retornos. Nas áreas urbanas, normalmente existem no máximo dois retornos na WF, pois a maioria dos alvos são estruturas opacas e rígidas, como edificações e estradas pavimentadas.

Zaletnyik et al. (2010) realizaram a classificação não supervisionada de WFs medidas com o sistema ALTM 3100 da Optech, utilizaram o algoritmo Kohonens's Self-Organizing Map e Redes Neurais Artificiais. Primeiramente recortaram os dados na área de estudo em um polígono com dimensão de aproximadamente 50 m x 65 m

e separaram as WFs com um ou múltiplos retornos. Utilizaram para isso o zero da função que determinou o número de retornos, conforme a metodologia proposta por Chauve et al. (2007). Parâmetros de amplitude, desvio padrão, coeficientes de assimetria e curtose foram utilizados para definir a forma dos picos. Classificaram os pontos sobre áreas com e sem vegetação. Para as áreas com vegetação definiram as classes de vegetação arbórea e vegetação rasteira. As áreas sem vegetação correspondiam a telhados, estradas pavimentadas e calçadas, e com o tempo dos picos das WFs vizinhas definiram se a feição estava acima ou no nível do terreno. Para a utilização do tempo consideraram a WF comparada com as suas vizinhas mais próximas na mesma linha do perfilamento, considerando no máximo 80 WFs antes ou após. Isto é possível se a nuvem de pontos representa um terreno plano com pequenas dimensões. No referido estudo, a distância máxima considerada é igual a 20 m antes ou após da WF analisada.

No estudo de Toth et al. (2011) foi realizada a comparação de métodos para a simples detecção de picos nas WFs, sendo mais rápido o processamento dos dados levantados em área urbana com o método do limiar. Obtiveram 85 % de acerto na classificação de 5.934 WFs. Os autores também fazem uma descrição de sistemas TLS FWF móveis capazes de digitalizar a WF a partir de plataformas como veículos automotores.

Niemeyer et al. (2011) realizaram a classificação supervisionada das WFs com Campos Aleatórios Condicionais. Nesta abordagem probabilística cada ponto é considerado um nó na modelagem de um grafo, enquanto as bordas representam correspondência para as arestas vizinhas mais próximas. Para a classificação das WFs utilizaram os parâmetros de amplitude, largura do pico e número de retornos. Considerando uma esfera de raio igual a 1,25 m foi calculada a variância do vetor normal da vizinhança local, diferença de altura entre o primeiro e o último retorno, distância de cada retorno ao MDT, análise das componentes principais por autovetores para definir regiões planas na nuvem de pontos, feições de bordas, além da geometria das feições para a classificação. Com a metodologia obtiveram acurácia global de 94 % na classificação dos pontos.

ZHU et al. (2011) desenvolveram um algoritmo progressivo para a decomposição Gaussiana da WF onde os ruídos são filtrados e o sinal é suavizado, os picos são detectados através de ponto de máximo local. A partir da posição destes é realizada a modelagem com a função Gaussiana. Quando a diferença entre

a curva modelada e a posição do pico é maior que a tolerância estabelecida, é aplicado um parâmetro de mudança na posição do pico progressivamente, até que a tolerância da modelagem seja atendida.

Wu (2012) realizou a deconvolução da WF objetivando parâmetros para a estimação de biomassa da vegetação e reconstrução tridimensional de espécies de árvores. Para isto, utilizou WFs simuladas geradas pelo software Digital Imaging and Remote Sensing Image Generation e também foram utilizadas WFs medidas com o sistema ALTM 3100EA da Optech. Realizou a deconvolução da WF utilizando o filtro de Wiener, Método dos Mínimos Quadrados Não Negativos, sendo o melhor desempenho encontrado utilizando o algoritmo de Richardson-Lucy.

Gumerov (2014), com metodologia de decomposição Gaussiana e detecção de picos fracos abaixo da copa de árvores, gerou MDT com aumento de 12 % na quantidade de pontos em comparação com os pontos provenientes de software comercial.

Ristorcelli et al. (2014) utilizaram o algoritmo DELIS (n-Dimensional Estimation of Lidar Signals) para modelagem de WFs de um sistema LIDAR orbital a partir de WFs simuladas para um sistema ALS, com parâmetros de emissão do feixe LASER do sistema comercial Riegl LMS Q680-i, para três tipos de vegetação: milho, laranja e floresta tropical. Na plantação de milho foi considerado espaçamento de 0,8 m entre as plantas e altura máxima de 2,1 m. Pomares de laranjas com espaçamento de 4,0 m entre as plantas e altura de 2,8 m e 4,0 m. A floresta tropical foi simplificada com 216 árvores distribuídas homogeneamente e altura máxima das copas de 30,0 m. O feixe LASER foi simulado com resolução espectral de 1.557 nm e 1.064 nm, frequências de operação de 80 kHz, 200 kHz e 400 kHz, com alturas de voo de 1.500 m, 1.100 m e 800 m, com os diâmetros dos footprints de 0,75 m, 0,55 m e 0,40 m, respectivamente. A partir das WFs simuladas para o sistema ALS, foram modeladas as WFs para um sistema LIDAR FWF orbital, considerado altura de voo de 500 km e footprint de 20,0 m, com as mesmas resoluções espectrais e frequências de operação do sistema ALS. De acordo com os autores a modelagem do sinal do sistema orbital foi satisfatória, mas dependendo da resolução radiométrica da emissão do feixe LASER erros de até 30 % podem ocorrer no sinal retroespalhado, utilizando o comprimento de onda de 1.557 nm este erro é reduzido para 10 %.

Slota (2015) criou uma metodologia para a definição de pontos em quinas de telhados a partir de WFs simuladas. A determinação da influência do ângulo de interseção do feixe com o alvo foi realizada através de um coeficiente de decréscimo da amplitude. Para isto, utilizou a largura à direita e esquerda dos pontos de máximo dos picos, amplitude, divergência do feixe e velocidade de grupo LASER, assimetria dos picos e potência do sinal recebido. A correção das distâncias dos pontos foi realizada com base na equação do plano definido pelo telhado da edificação. A acurácia horizontal das quinas foi melhor que a dimensão do footprint.

Tseng et al. (2015), utilizaram três conjuntos de WFs medidas com os sistemas Leica ALS60, Riegl LMS-Q680i e Optech ALTM Pegasus HD400 em metodologias de decomposição baseada em wavelets e na quantidade de retornos das WFs. Os pontos da área de estudo foram classificados de acordo com as feições de grama, árvore, estrada, solo exposto e edificações. A distância de Bhattacharyya foi utilizada para a seleção dos parâmetros mais representativos a serem aplicados nas três metodologias de classificação desenvolvidas. A primeira metodologia utiliza os parâmetros da WF decomposta em retornos individuais, amplitude, largura e área da seção de retroespalhamento do sinal de retorno. A segunda e a terceira metodologias utilizam a combinação de parâmetros para a classificação de retornos únicos e múltiplos. Incluem os parâmetros da primeira metodologia, a média do número de retornos e da largura do sinal de retorno, variação de tempo do primeiro e último retorno, desvios padrão da amplitude, largura, seção de retroespalhamento e sobreposição dos retornos. Na terceira metodologia foram acrescentadas as informações RGB de uma ortofoto. Realizaram a classificação supervisionada das feições de interesse através de algoritmo com Support Vector Machine. Obtiveram os melhores resultados utilizando a terceira metodologia de classificação, com índice Kappa de 0,8 para os dados obtidos com os sistemas ALS60 e LMS-Q680i e 0,77 para o sistema ALTM Pegasus HD400. A acurácia global da classificação na terceira metodologia ficou acima de 80 % para os dados obtidos com os três sistemas ALS FWF.

Hancock et al. (2017) modelaram a vegetação arbórea com voxels gerados a partir da deconvolução de WFs, medidas com o sistema ALS Leica ALS50-II, e pontos medidos com o sistema TLS Riegl VZ400. Os voxels apresentam resolução horizontal de 1,5 m e vertical de 0,50 m e de acordo com os autores a metodologia

pode ser aplicada no monitoramento da saúde da vegetação, medidas do dossel em florestas com copas fechadas e quantificação da área foliar.

Casalegno et al. (2017) classificaram pontos em áreas urbanas com vegetação arbórea, estimaram o volume, altura e a densidade dos extratos utilizando modelagem com voxel para os pontos gerados por deconvolução de WFs. Ressaltam que a metodologia pode auxiliar no controle da supressão vegetal, no entanto, o uso de WFs é experimental, pois os levantamentos ainda apresentam alto custo e demandam mais espaço para o armazenamento dos dados.

Qin et al. (2017), utilizando WFs medidas em áreas com plantação de milho, estimaram a fração absorvida da radiação fotossinteticamente ativa, o parâmetro FPAR (fraction of photosynthetically active radiation). O valor do FPAR determinado através da metodologia apresentou forte correlação com o medido em campo. Geraram um perfil com a distribuição vertical do FPAR, mencionaram que existe superabundância de informações nas WFs para este tipo de aplicação.

Vicent et al. (2017) utilizaram WFs medidas com o sistema Riegl LMSQ560 para complementar a estimação do índice de área foliar (Leaf Area Index - LAI), medidos com o sensor óptico LAI2200. Realizaram o processamento das WFs com o software RiPROCESS através de funções Gaussianas para determinar os a quantidade de retornos. A partir da amplitude, largura da base do pulso e distância calcularam o índice de energia do sinal de retorno que foi comparado com os dados medidos pelo sensor LAI2200. Os autores concluíram que os dados LIDAR com WF, obtidos por plataformas aerotransportadas e terrestres, podem ser utilizadas em conjunto com o sensor LAI2200 e que dados com WFs apresentam grande relevância para estudos florestais.

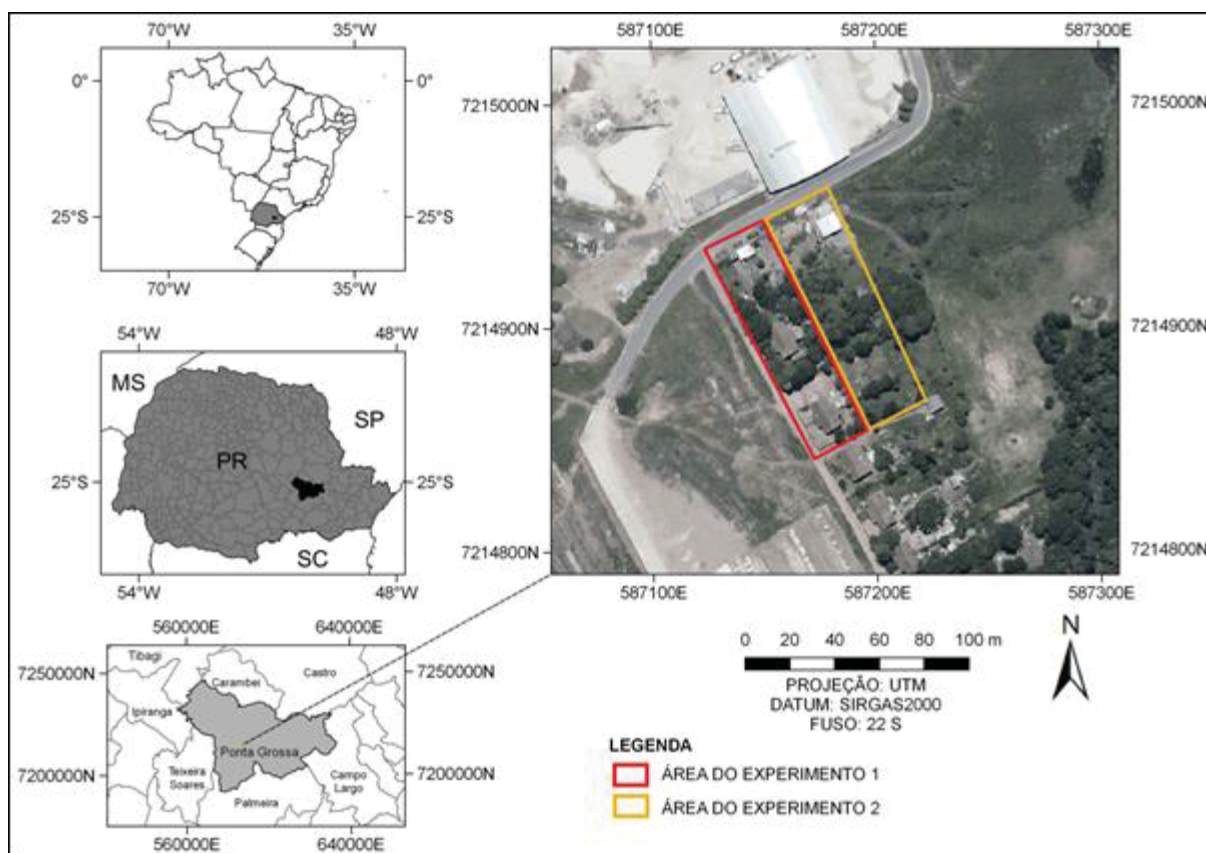
Chen et al. (2018) utilizando WFs medidas em duas áreas e com diferentes sistemas ALS, Optech ALTM 3100 e Riegl LMS-Q560, realizaram a decomposição com as funções Gaussiana, Gaussiana Generalizada, Lognormal e Nakagami, e geraram pontos que foram agrupados de acordo com os atributos destas funções. Posteriormente geraram supervoxels homogêneos e os classificaram como vegetação e não vegetação aplicando Suport Vector Machine (SVM) e Random Forest (RF) algorithm. Para os dois conjuntos de WFs utilizando SVM obtiveram acurácia global de 98,2 % e 96,47 %, com o algoritmo RF os resultados foram de 98,16 % e 97,67 %.

3 MATERIAIS

Os algoritmos foram implementados no ambiente do FreeMat 4.1, o planejamento, a visualização da área de estudo e dos resultados foram realizados nos softwares CloudCompare 2.8 e QGIS 2.18, instalados em microcomputador com sistema operacional Windows 10 com 64 bits, processador Intel® Core i7, memória RAM de 8 GB, disco rígido com capacidade de armazenamento de 1 TB e placa de vídeo com 2 GB.

Os dados LIDAR com WF utilizados foram gentilmente cedidos pelo LACTEC. Estes são provenientes de aerolevantamento realizado com o sistema ALTM Pegasus HD500, em agosto de 2012, sobre a região do aeroporto da cidade de Ponta Grossa no estado do Paraná. Os polígonos vermelho e amarelo da Figura 3.1 ilustram as áreas dos experimentos 1 e 2.

FIGURA 3.1 – ÁREA DE ESTUDO



Fonte: O Autor (2018).

As imagens que geraram a ortofoto da Figura 3.1 não foram tomadas no aerolevantamento dos dados LIDAR com WF, não formam um conjunto de dados. A ortofoto na escala 1:2.000 é do ano de 2012 e está disponível no site do setor de Geoprocessamento Corporativo da Prefeitura de Ponta Grossa (<http://geoweb.pontagrossa.pr.gov.br/>).

A nuvem de pontos gerada com o software DDR é ilustrada na Figura 3.2. Apresenta a densidade média de 5 pontos por metro quadrado, foi extraída em formato LAS 1.3 da American Society for Photogrammetry and Remote Sensing (ASPRS) LIDAR Data Exchange Format Standard.

FIGURA 3.2 – NUVEM DE PONTOS



Fonte: O Autor (2018).

O voo foi realizado com os parâmetros descritos no Quadro 3.1, com emissão de múltiplos pulsos e acionamento do IWD para a digitalização das WFs.

QUADRO 3.1 – PARÂMETROS DO VOO

ALTURA DE VOO (m)	ÂNGULO DE ABERTURA FOV (°)	FREQUÊNCIA DE OPERAÇÃO PRF (kHz)	FREQUÊNCIA DE VARREDURA (Hz)	VELOCIDADE DA AERONAVE (kts)	DIREÇÃO DE VOO
800	65	500	23	135	Leste - Oeste

Fonte: O Autor (2018).

A partir dos dados brutos do aerolevantamento geraram-se dois arquivos no formato ASCII (American Standard for Computer Information Interchange) conforme as informações descritas nos Quadros 3.2 e 3.3. O Quadro 3.2 ilustra o arquivo ASCII gerado no software DDR, com as informações tradicionais contidas na nuvem de pontos: coordenadas dos pontos na projeção UTM (E, N), datum SIRGAS2000, fuso 22S; altitude elipsoidal (h); amplitude (A) ou intensidade do sinal de retorno. São descritas também algumas informações adicionais: distância (D) entre cada ponto medido e o sensor; número do retorno (NR); número total de retornos (NT); coordenadas de emissão do feixe LASER (E_E , N_E , h_E); ângulo de emissão (α); desvio padrão do ângulo de emissão ($d\alpha$); atitude da aeronave no momento da emissão definida pelos ângulos Roll (ω), Pitch (φ) e Yaw (k); desvios padrão dos ângulos Roll ($d\omega$), Pitch ($d\varphi$) e Yaw (dk); e tempo GPS (TGPS).

QUADRO 3.2 – NUVEM DE PONTOS DO SOFTWARE DDR

E (m)	N (m)	h (m)	A (ND)	D (m)	NR	NT	E_E (m)	N_E (m)	h_E (m)	α (°)	$d\alpha$ (°)	ω (°)	φ (°)	k (°)	$d\omega$ (°)	$d\varphi$ (°)	dk (°)	TGPS (s)

Fonte: O Autor (2018).

O TGPS é apresentado em segundos (s) e foi registrado pelo receptor do GPS, corresponde ao tempo em que o rastreamento ocorreu, considerando o início da semana na zero hora de domingo (OPTTECH, 2012a). Os dados contidos em cada amostra de WF digitalizada são ilustrados no Quadro 3.3. As amostras de amplitude da WF são digitalizadas para o feixe LASER emitido (0) e sinal de retorno (1). O TGPS é utilizado para a identificação dos parâmetros de emissão do feixe LASER que foram descritos no Quadro 3.2.

QUADRO 3.3 – AMOSTRA DE WF

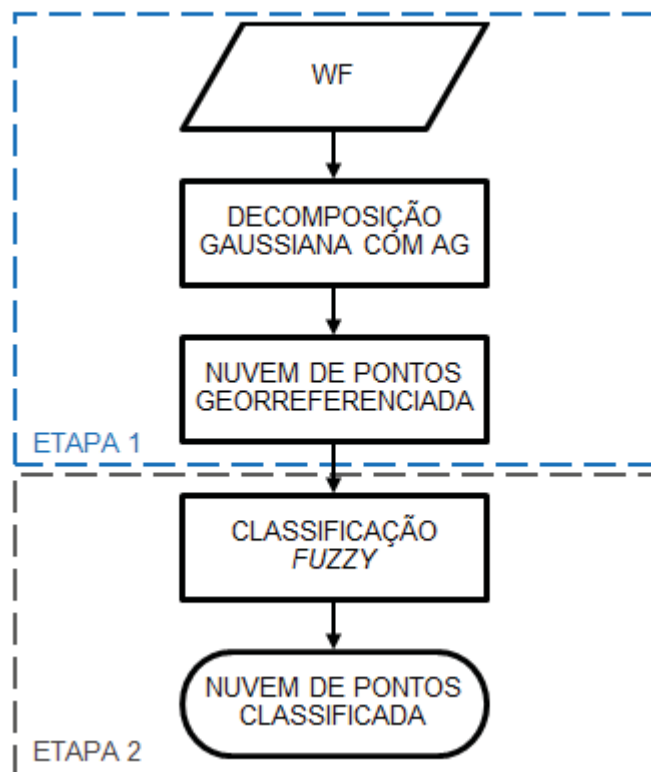
TGPS (s)	CÓDIGO: EMIÇÃO (0) / RETORNO (1)	TEMPO DE RETORNO (s)	AMOSTRAS DE AMPLITUDE (ND)

Fonte: O Autor (2018).

4 METODOLOGIA

A metodologia desenvolvida compreende duas etapas principais. A primeira é a geração da nuvem de pontos georreferenciada. A segunda etapa é a classificação, conforme ilustra a Figura 4.1.

FIGURA 4.1 – ETAPAS DA METODOLOGIA



Fonte: O Autor (2018).

A geração da nuvem de pontos georreferenciada foi realizada a partir do tempo médio dos picos detectados na decomposição Gaussiana das WFs com Algoritmos Genéticos, conforme descrito na Seção 4.1. Posteriormente, na Seção 4.2 foram definidas WFs características para as feições de interesse contidas na área de estudo. A classificação dos pontos com abordagem Fuzzy baseada em regras é apresentada na Seção 4.3. A avaliação da qualidade da classificação utilizando a matriz de confusão é descrita na Seção 4.4.

4.1 DECOMPOSIÇÃO GAUSSIANA COM ALGORITMOS GENÉTICOS

A quantidade de picos contidos na WF não é conhecida “*a priori*”. Sendo assim, os parâmetros de tempo médio, amplitude e desvio padrão destes picos também não são conhecidos. A solução proposta nesta tese foi gerar o primeiro conjunto de parâmetros utilizando um algoritmo de simples detecção de picos (SDP) com ponto de máximo local (PML) em uma etapa inicial, posteriormente realizou-se a decomposição Gaussiana da WF com Algoritmos Genéticos (AG) com tolerância de 20 ND nos valores de amplitude dos picos nas curvas modeladas e observadas. O AG corresponde ao processo iterativo de busca e otimização destes parâmetros e a função Gaussiana foi utilizada por ser tradicionalmente aplicada na decomposição de WFs.

Os parâmetros com a possível solução são codificados como uma cadeia genética binária de cromossomos. Um conjunto de soluções possíveis (indivíduos) é chamado de população (geração). Cada solução é avaliada através da função de aptidão (fitness), que ordena as soluções de acordo com o valor da diferença entre a curva digitalizada e a modelada, sendo então as melhores soluções identificadas e combinadas para a criação da nova geração.

Com a combinação de dois indivíduos com alto valor de fitness espera-se que um indivíduo melhor seja gerado, com maior fitness, pois herdou as melhores características dos indivíduos que o geraram. Com isto, a nova geração deve ser melhor que a anterior. Este processo é repetido iterativamente até que o critério de parada seja satisfeito.

A combinação de duas soluções é o cruzamento. Aplicado aleatoriamente sobre dois indivíduos com objetivo de criar uma nova solução com características dos pais. A partir de dois cromossomos, escolhe-se um ponto em um deles e realiza-se a troca de bits em um dos lados deste ponto, produzindo um par de cromossomos descendentes. A seleção dos pais é realizada randomicamente, considerando apenas os indivíduos com o melhor fitness. Isso garante que apenas as boas soluções sejam combinadas.

Através do operador de mutação o processo de cruzamento é acelerado e evita-se que fique estagnado em um mínimo local. Após cada iteração um indivíduo tem seus bits alterados aleatoriamente, produzindo um novo valor para um dos parâmetros.

No AG implementado foi utilizado o fitness igual a 95 % e as probabilidades de cruzamento e mutação foram respectivamente de 30 % e 20 %. O número de cromossomos é variável, depende da quantidade de picos detectados previamente na SDP, a população foi definida com 50 indivíduos. O processo de busca é encerrado quando a diferença entre a curva gerada na modelagem com os parâmetros e a curva digitalizada é inferior ao limiar previamente definido para o fitness, sendo o número máximo de iterações igual a 1.000.

Conforme descrito anteriormente, na modelagem de uma curva com a função Gaussiana a amplitude corresponde à altura do pico e apresenta o valor máximo de 4.095 níveis digitais (ND), pois o sistema Digitizer (IWD) realiza a digitalização da WF com 12 bits. A posição do pico no sinal de retorno corresponde ao tempo médio registrado e varia entre 0 e 499 ns. O desvio padrão controla a largura da base do pico e considerou-se a sua variação entre 0 e 15. Os valores digitalizados pelo sistema IWD são números inteiros entre 0 e 4.095, o que corresponde ao total de 4.096 ND, conforme expresso na Equação (4.1).

$$ND_{M\acute{A}X} = 2^{12} = 4.096 \quad (4.1)$$

A Figura 4.2 ilustra uma amplitude de 153 ND representada por um cromossomo com 12 valores binários.

FIGURA 4.2 – CROMOSSOMO COM 12 BITS

0	0	0	0	1	0	0	1	1	0	0	1
---	---	---	---	---	---	---	---	---	---	---	---

FONTE: Adaptado de Negnevitsky (2005)

A conversão da amplitude (A_j) de 153 ND para o sistema binário é feita através da Equação (4.2).

$$A_j = 0 \times 2^{12} + 0 \times 2^{11} + 0 \times 2^{10} + 0 \times 2^9 + 0 \times 2^8 + 1 \times 2^7 + 0 \times 2^6 + \\ + 0 \times 2^5 + 1 \times 2^4 + 1 \times 2^3 + 0 \times 2^2 + 0 \times 2^1 + 1 \times 2^0 = 153 \quad (4.2)$$


O sistema IWD é capaz de armazenar no máximo 499 amostras devido ao método de truncamento que reduz a quantidade de dados. Este método é utilizado para tornar a digitalização da WF tecnicamente viável, devido à alta frequência de

operação do sistema ALTM Pegasus HD500 (OPTTECH, 2012a). Isto condiciona que a representação da média (μ_j) seja feita com 9 bits, valores entre 0 e 499, conforme a Equação (4.3).

$$\begin{aligned}\mu_j = 1 \times 2^9 + 1 \times 2^8 + 1 \times 2^7 + 1 \times 2^6 + 1 \times 2^5 + 1 \times 2^4 + \\ + 0 \times 2^3 + 0 \times 2^2 + 1 \times 2^1 + 1 \times 2^0 = 499\end{aligned}\quad (4.3)$$

O último parâmetro é o desvio padrão (σ_j), que por ser um valor real foi representado com 16 bits. Sendo assim, a cadeia binária que representa a solução para uma Gaussiana tem 37 (12+9+16) bits. Para o caso de duas Gaussianas são necessários 74 bits, e assim sucessivamente. A Figura 4.3 ilustra a modelagem Gaussiana para a WF com um pico (j), sendo os valores de amplitude (A_j), tempo médio (μ_j) e desvio padrão (σ_j), respectivamente iguais a 1.562 ND, 75 ns e 3,046875.

FIGURA 4.3 – CROMOSSOMO COM 37 BITS



Fonte: O Autor (2018).

Cada pico da WF é um conjunto (A_j, μ_j, σ_j) que pode ser reproduzido com uma curva Gaussiana (G). O cromossomo que representa uma WF composta por dois picos apresenta seis parâmetros ($A_1, \mu_1, \sigma_1, A_2, \mu_2, \sigma_2$). A combinação das duas curvas modeladas (C_{MOD}) pode ser representada através da soma expressa na Equação (4.4).

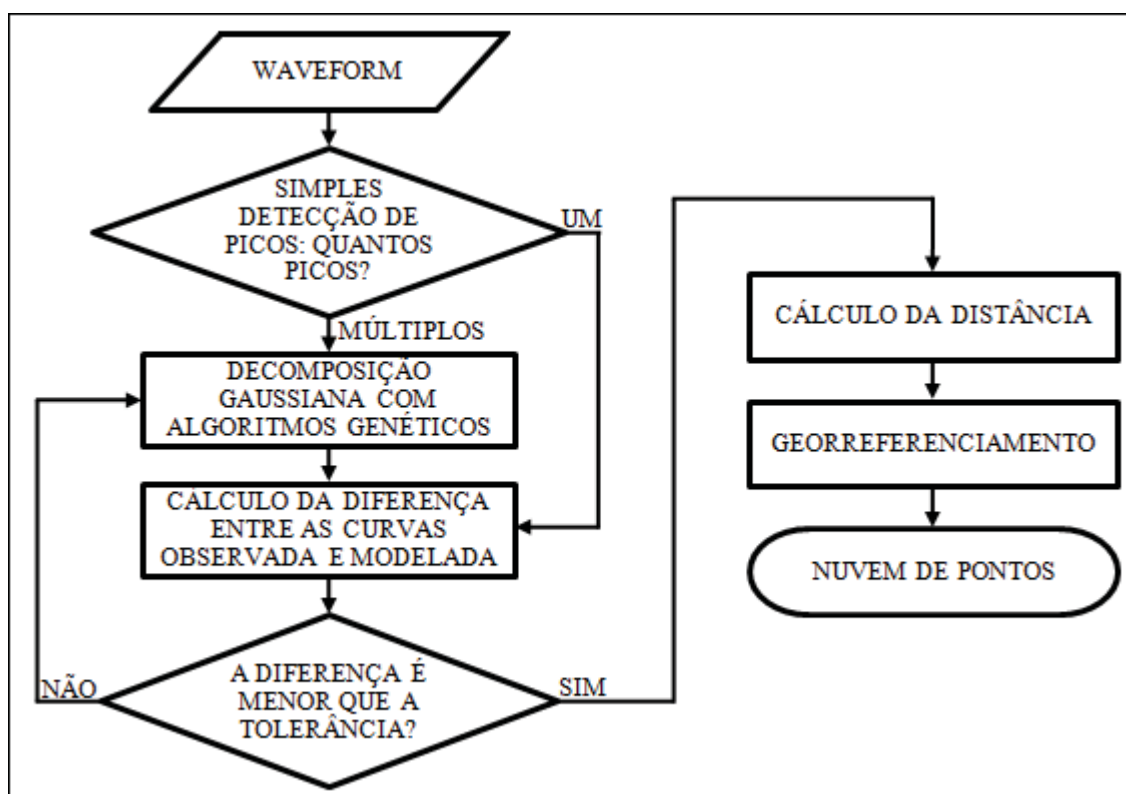
$$C_{MOD} = G(A_1, \mu_1, \sigma_1) + G(A_2, \mu_2, \sigma_2) \quad (4.4)$$

Procuram-se valores para os parâmetros que gerem uma solução semelhante à curva derivada das amostras geradas com o IWD. Isto é avaliado através da função de aptidão que corresponde à diferença (DIF) entre a curva modelada (C_{MOD}) e a curva digitalizada (C_{DIG}), conforme a Equação (4.5).

$$DIF = |C_{DIG} - C_{MOD}| \quad (4.5)$$

O fluxograma com as etapas da metodologia de decomposição Gaussiana da WF com AG até a geração da nuvem de pontos georreferenciada é apresentado na Figura 4.4.

FIGURA 4.4 – FLUXOGRAMA DA DECOMPOSIÇÃO GAUSSIANA COM AG



Fonte: O Autor (2018).

No algoritmo de SPD com PML a WF é analisada para a estimação da quantidade inicial de picos e dos parâmetros de amplitude e média. Quando apenas um pico é detectado na SPD, calcula-se o desvio padrão a partir das amostras de amplitude e este é modelado com uma curva Gaussiana. Posteriormente, com a função de aptidão calcula-se a diferença (DIF) entre a curva digitalizada (C_{DIG}) e a curva modelada (C_{MOD}). Se a diferença for superior à tolerância (TOL) de 20 ND, a WF passa pela decomposição Gaussiana com AG e novos parâmetros são determinados. A curva modelada é avaliada com a função de aptidão, se a diferença for inferior à tolerância, o processo é encerrado e os parâmetros gaussianos da

curva são determinados. Caso contrário, a WF é decomposta iterativamente no AG até que o critério de parada seja atendido. A tolerância de 20 ND foi definida considerando que a digitalização da WF depende de fatores externos, tais como a atmosfera, ruídos presentes no sinal além de imperfeições na fabricação do sensor e do ringing effect.

Quando múltiplos picos são detectados no algoritmo de SDP a WF é decomposta com AG e os parâmetros gaussianos são determinados. Se a diferença entre a curva digitalizada e a modelada é inferior à tolerância, o processo é encerrado. Caso contrário, a WF passa novamente pela decomposição Gaussiana com AG até que o critério de parada seja atendido e os parâmetros determinados.

O sistema IWD utiliza o valor constante de 200 ND como referência para as amplitudes, sendo os valores digitalizados relativos a esta constante. Com a tolerância de 20 ND sobre o valor de referência para as amplitudes, estabeleceu-se o limite inferior de amplitude igual a 220 ND para determinar os picos contidos na WF.

A partir do tempo médio do pico foi calculada a distância de cada pico detectado na WF. Através do TGPS foram identificados os parâmetros de emissão do feixe LASER que originaram estes picos. Estes parâmetros, apresentados anteriormente no Quadro 3.2, foram utilizados para o georreferenciamento da nuvem de pontos conforme a Equação 2.27.

O Quadro 4.1 apresenta as informações da nuvem de pontos gerada através da metodologia de decomposição Gaussiana com AG: coordenadas (E, N) dos pontos na projeção Universal Transversa de Mercator (UTM), datum SIRGAS2000, fuso 22S; altitude elipsoidal (h); amplitude (A); desvio padrão (σ), tempo médio (μ), distância (D) inclinada entre o ponto medido e o sensor; número do retorno (NR); número total de retornos (NT); TGPS.


QUADRO 4.1 – INFORMAÇÕES DA NUVEM DE PONTOS GERADA

E (m)	N (m)	h (m)	A (ND)	σ	μ (ns)	D (m)	NR	NT	TGPS (s)

Fonte: O Autor (2018).

A Figura 4.5 ilustra a decomposição Gaussiana de uma WF através da metodologia com AG. Foram detectados cinco picos modelados com as Gaussianas representadas pelas linhas tracejadas e pontilhadas na cor azul. A soma destas Gaussianas é a curva modelada para a WF do sinal de retorno, representada com a linha azul contínua. A forma da curva modelada se aproxima da WF digitalizada, representada com a linha vermelha contínua. A linha verde contínua representa a curva gerada pela diferença entre a curva digitalizada e a curva modelada, nesta curva os picos apresentam amplitudes inferiores ao limite de 220 ND. A WF do pulso LASER emitido é ilustrada com a linha preta contínua.


FIGURA 4.5 – CINCO RETORNOS MODELADOS COM GAUSSIANS



Fonte: O Autor (2018).

Na Figura 4.5 foi subtraído o valor constante de 200 ND nos valores de amplitude para destacar as Gaussianas que modelaram os picos detectados na WF do sinal de retorno. A Figura 4.6 ilustra a modelagem de uma WF simples, com picos relativamente bem definidos. Por este motivo, utilizando apenas o algoritmo de SDP com PML foi possível determinar cinco retornos, conforme os picos ilustrados com as circunferências vermelhas e as cinco curvas Gaussianas representadas com as linhas tracejadas.

FIGURA 4.6 – WF SIMPLES



Fonte: O Autor (2018).

Na Figura 4.6 a WF do pulso emitido está representada pela linha contínua preta. A linha contínua vermelha representa a WF do sinal de retorno e os picos estão representados com as circunferências vermelhas. O segundo e o terceiro retornos apresentam baixos valores de amplitude, respectivamente 234 e 236 ND, porém estão acima de 220 ND que corresponde ao limiar de amplitude. O software DDR não detectou estes retornos.

Na Tabela 4.1 estão às distâncias inclinadas calculadas para os cinco retornos detectados através da metodologia de decomposição Gaussiana (DG) com AG. Estas foram calculadas utilizando os tempos dos retornos detectados e a Equação (2.25). O software DDR detectou três retornos e as correspondentes distâncias também podem ser observadas. As diferenças foram calculadas com a subtração das distâncias obtidas através da metodologia das provenientes do software DDR.

TABELA 4.1 – DISTÂNCIAS CALCULADAS PARA A WF SIMPLES


RETORNO	DISTÂNCIAS (m)		DIFERENÇAS (m)
	DDR	DG	
1	790,616	790,674	-0,058
2	Não detectou	792,923	-
3	Não detectou	793,822	-
4	795,600	795,771	-0,171
5	797,879	797,721	0,158

Fonte: O Autor (2018).

O software DDR determinou apenas os retornos de número um, quatro e cinco, que foram utilizados na comparação das distâncias e calculadas as diferenças de -0,058 m, -0,171 m e 0,158 m, respectivamente. Estas diferenças também estão relacionadas ao método utilizado na detecção dos picos.

A Figura 4.7 ilustra a modelagem de uma WF complexa. Com a SDP foram detectados apenas dois picos, o primeiro e o último. Com a metodologia foram detectados os cinco retornos destacados com as circunferências vermelhas e modelados com as Gaussianas das linhas tracejadas. O software DDR determinou quatro retornos.

FIGURA 4.7 – WF COMPLEXA



Fonte: O Autor (2018).

As Gaussianas de número dois, três e quatro da Figura 4.7 representam retornos intermediários que não apresentam PML, e por este motivo não foram detectados na SDP. A sobreposição de curvas após o primeiro pico faz a cauda direita ficar mais longa, diminuindo a simetria da Gaussiana. Na Tabela 4.2 são apresentadas as distâncias inclinadas calculadas através da metodologia e no software DDR.

TABELA 4.2 – DISTÂNCIAS CALCULADAS PARA A WF COMPLEXA

RETORNO	DISTÂNCIAS (m)		DIFERENÇAS (m)
	DDR	DG	
1	789,882	790,147	-0,265
2	Não detectou	791,347	-
3	793,039	792,846	0,193
4	797,622	797,494	0,128
5	798,513	798,544	-0,031

Fonte: O Autor (2018).

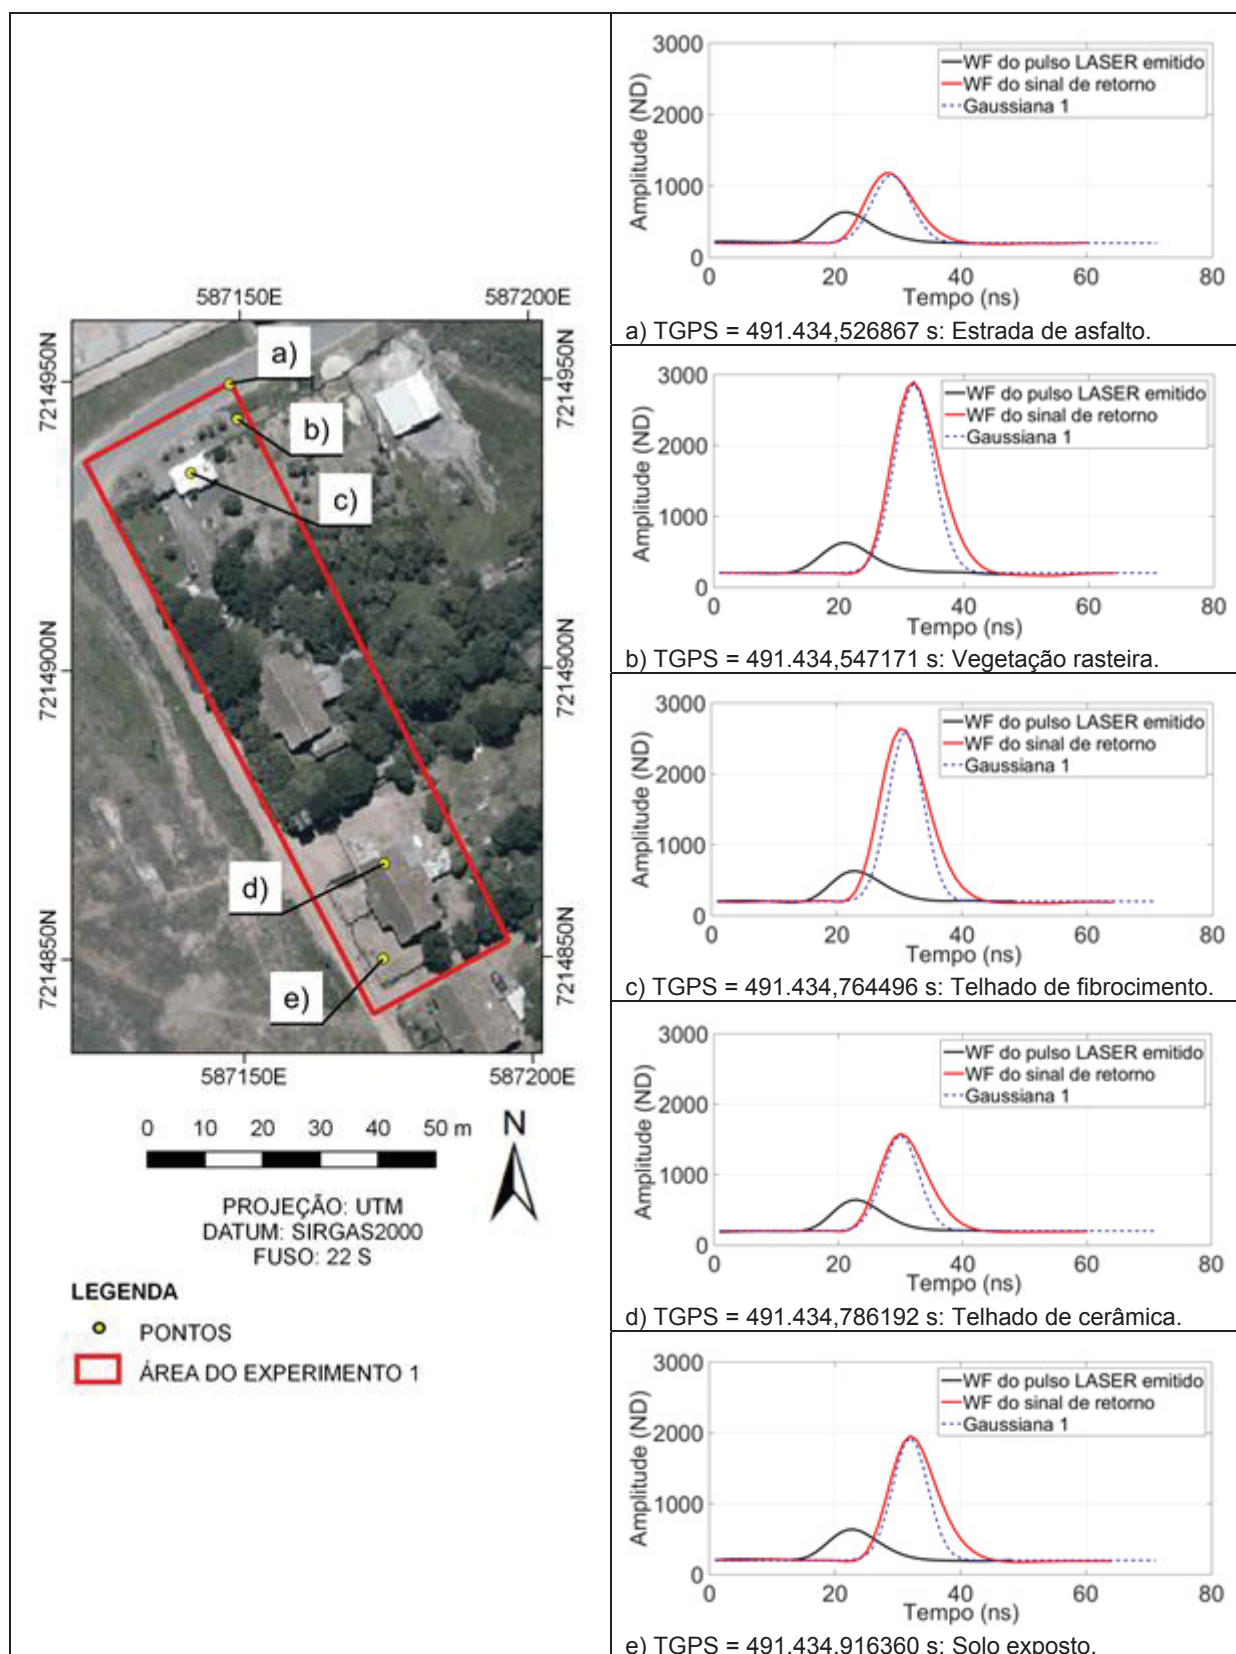
Na Tabela 4.2 são apresentadas as diferenças de -0,265 m, 0,193 m, 0,128 m e -0,031 m nos valores das distâncias inclinadas dos retornos um, três, quatro e cinco. As maiores diferenças foram observadas no primeiro e terceiro retornos, são vizinhas ao segundo pico que não foi detectado pelo software DDR.

Após a detecção dos retornos contidos nas WFs, e conhecendo-se a posição de disparo e direção do feixe LASER, realizou-se o georreferenciamento dos pontos através da Equação (2.27).

4.2 WAVEFORMS CARACTERÍSTICAS

As WFs de feições existentes na área de estudo foram analisadas para a definição das suas formas características. A Figura 4.8 ilustra as WFs geradas a partir da reflexão do feixe LASER por superfícies que causaram retorno único na área do Experimento 1. Nas Figuras 4.8a, 4.8b, 4.8c, 4.8d e 4.8e foram representadas as WFs dos sinais de retorno da estrada de asfalto, vegetação rasteira, telhado de fibrocimento, telhado de cerâmica e solo exposto. As linhas tracejadas representam as curvas Gaussianas geradas na modelagem dos picos das WFs.

FIGURA 4.8 – WFS GERADAS POR RETORNOS ÚNICOS



Fonte: O Autor (2018).

A modelagem Gaussiana para a WF da vegetação rasteira, representada na Figura 4.8b, foi a que mais se aproximou da WF do sinal de retorno, os picos estão próximos e apresentaram o mesmo tempo de 31 ns, o valores das amplitudes foram de 2.893 e 2.896 ND, o que resulta em uma diferença de 3 ND. Lembrando que a digitalização da WF é feita no sistema IWD, que é externo ao sensor do LASER, esta diferença é aceitável. As WFs amostradas e modeladas da estrada de asfalto e solo exposto também apresentaram o mesmo tempo, porém as diferenças de amplitude foram respectivamente de 11 e 9 ND. Para as WFs dos telhados de fibrocimento e cerâmica houve diferença de respectivamente 16 e 10 ND nos valores de amplitude e 1 ns nos tempos determinados com a modelagem Gaussiana.

No Quadro 4.2 estão os valores dos parâmetros determinados na decomposição Gaussiana das WFs ilustradas na Figura 4.8. Também são apresentados o número total de retornos (NT), o número do retorno (NR) em ordem crescente de detecção e a descrição da feição que refletiu o feixe LASER.

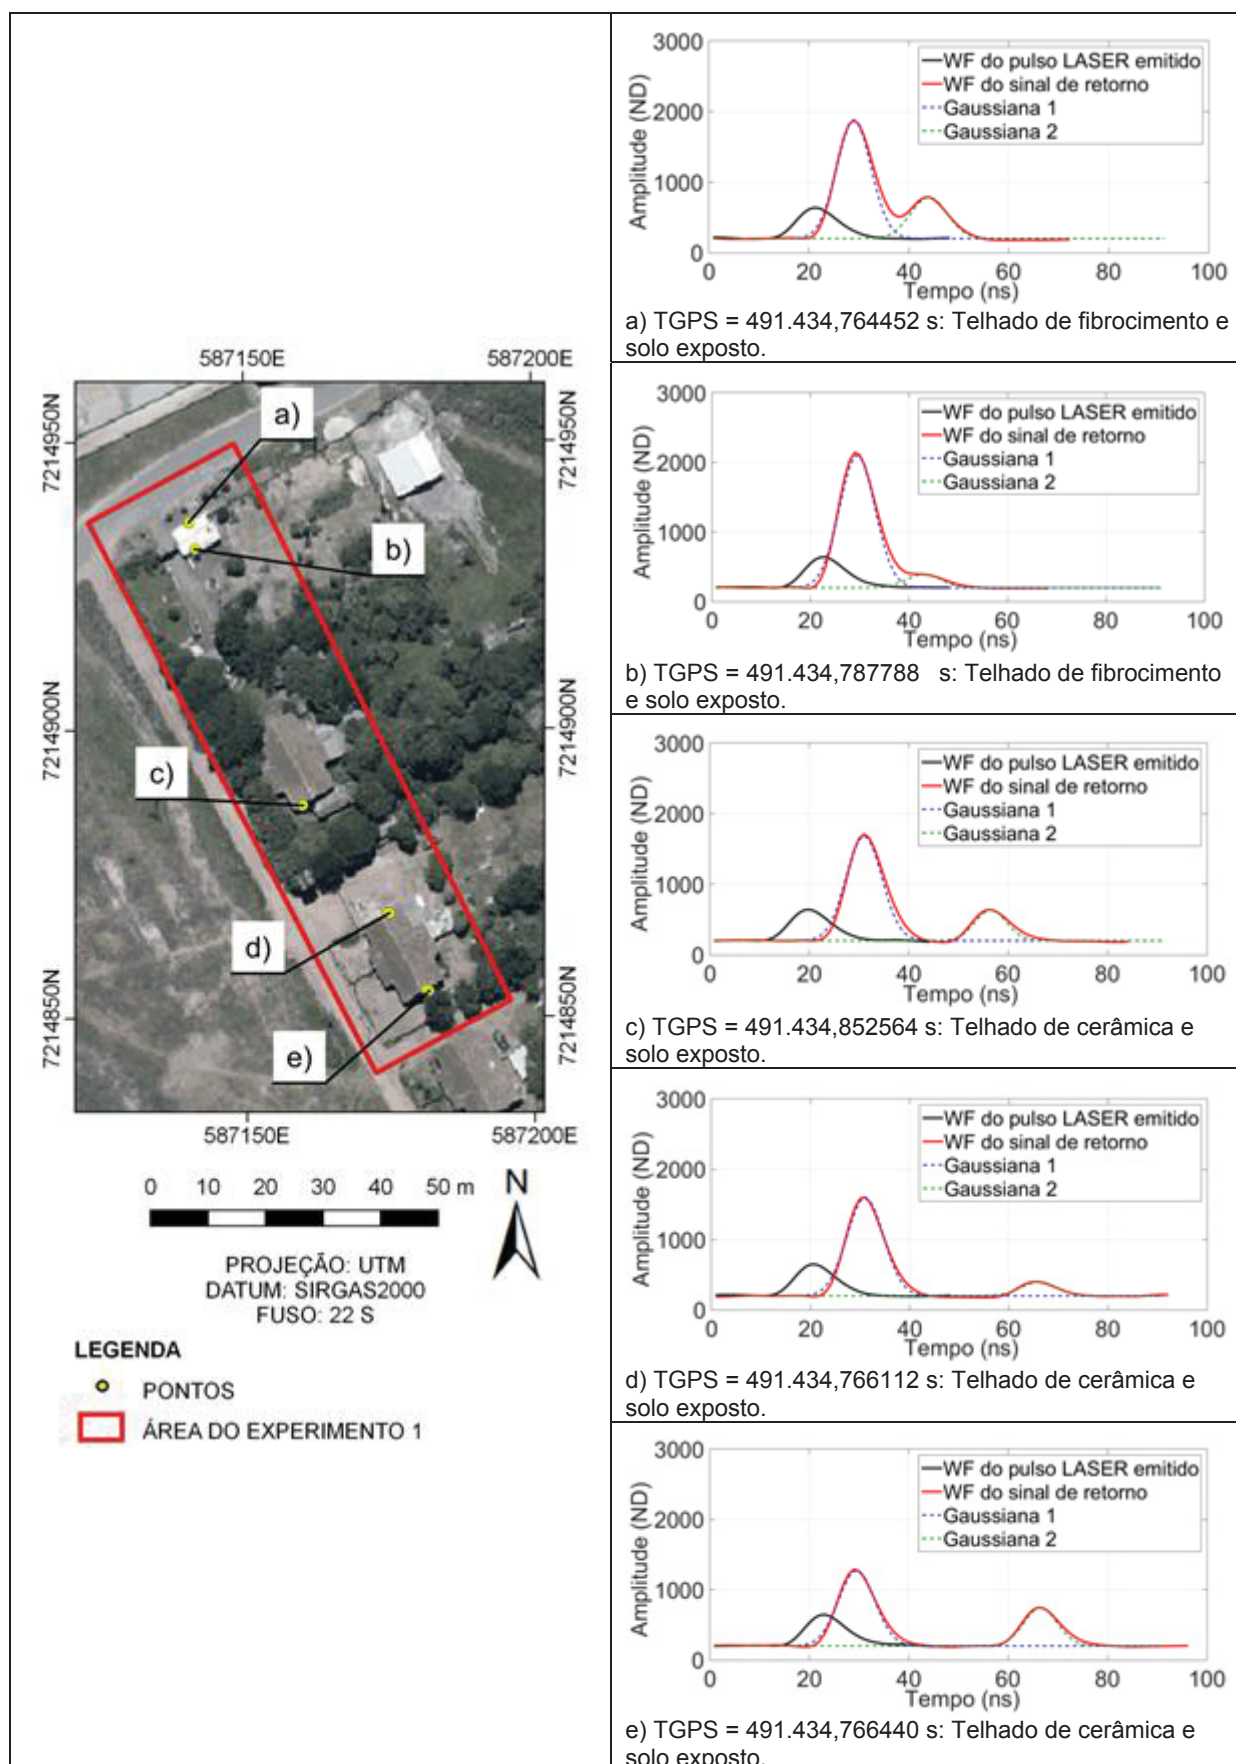
QUADRO 4.2 – PARÂMETROS DAS WFS COM RETORNOS ÚNICOS

TGPS (s)	NT	NR	A (ND)	μ (ns)	σ	FEIÇÃO
491.434,526867	1	1	1.168	30	3,184582	Estrada de asfalto.
491.434,547171	1	1	2.888	31	2,761527	Vegetação rasteira.
491.434,764496	1	1	2.622	31	3,412158	Telhado de fibrocimento.
491.434,786192	1	1	1.571	30	3,481574	Telhado de cerâmica.
491.434,916360	1	1	1.946	31	2,898665	Solo exposto.

Fonte: O Autor (2018).

No Quadro 4.2 a WF da estrada de asfalto apresentou o menor valor de amplitude igual a 1.168 ND. A WF refletida pela vegetação rasteira apresentou o maior valor de amplitude igual a 2.888 ND, e o menor valor de desvio padrão igual a 2,761527. As amplitudes dos telhados de fibrocimento e cerâmica foram de 2.622 e 1.571 ND e os desvios padrão foram os maiores dentre os analisados, respectivamente de 3,412158 e 3,481574. Isto diminuiu a precisão na determinação do tempo destes picos, houve diferença de 1 ns entre o pico da curva modelada com a Gaussiana e a WF amostrada. As WFs de retornos únicos apresentaram os maiores valores de amplitude, pois a energia do sinal de retorno não foi dividida. A Figura 4.9 ilustra as WFs geradas pela reflexão do feixe LASER por quinas de telhado e solo exposto.

FIGURA 4.9 – WFS GERADAS POR QUINAS DE TELHADOS



Fonte: O Autor (2018).

Nas WFs das Figuras 4.9a e 4.9b os picos detectados estão sobrepostos, correspondem aos sinais de retorno das quinas do telhado de fibrocimento e solo exposto. As Figuras 4.9c, 4.9d e 4.9e, ilustram WFs das quinas de telhados de cerâmica e o solo exposto, os picos não estão sobrepostos indicando maior distância entre as superfícies. No Quadro 4.3 estão os parâmetros determinados.

QUADRO 4.3 – PARÂMETROS DAS WFS DE QUINAS DE TELHADOS

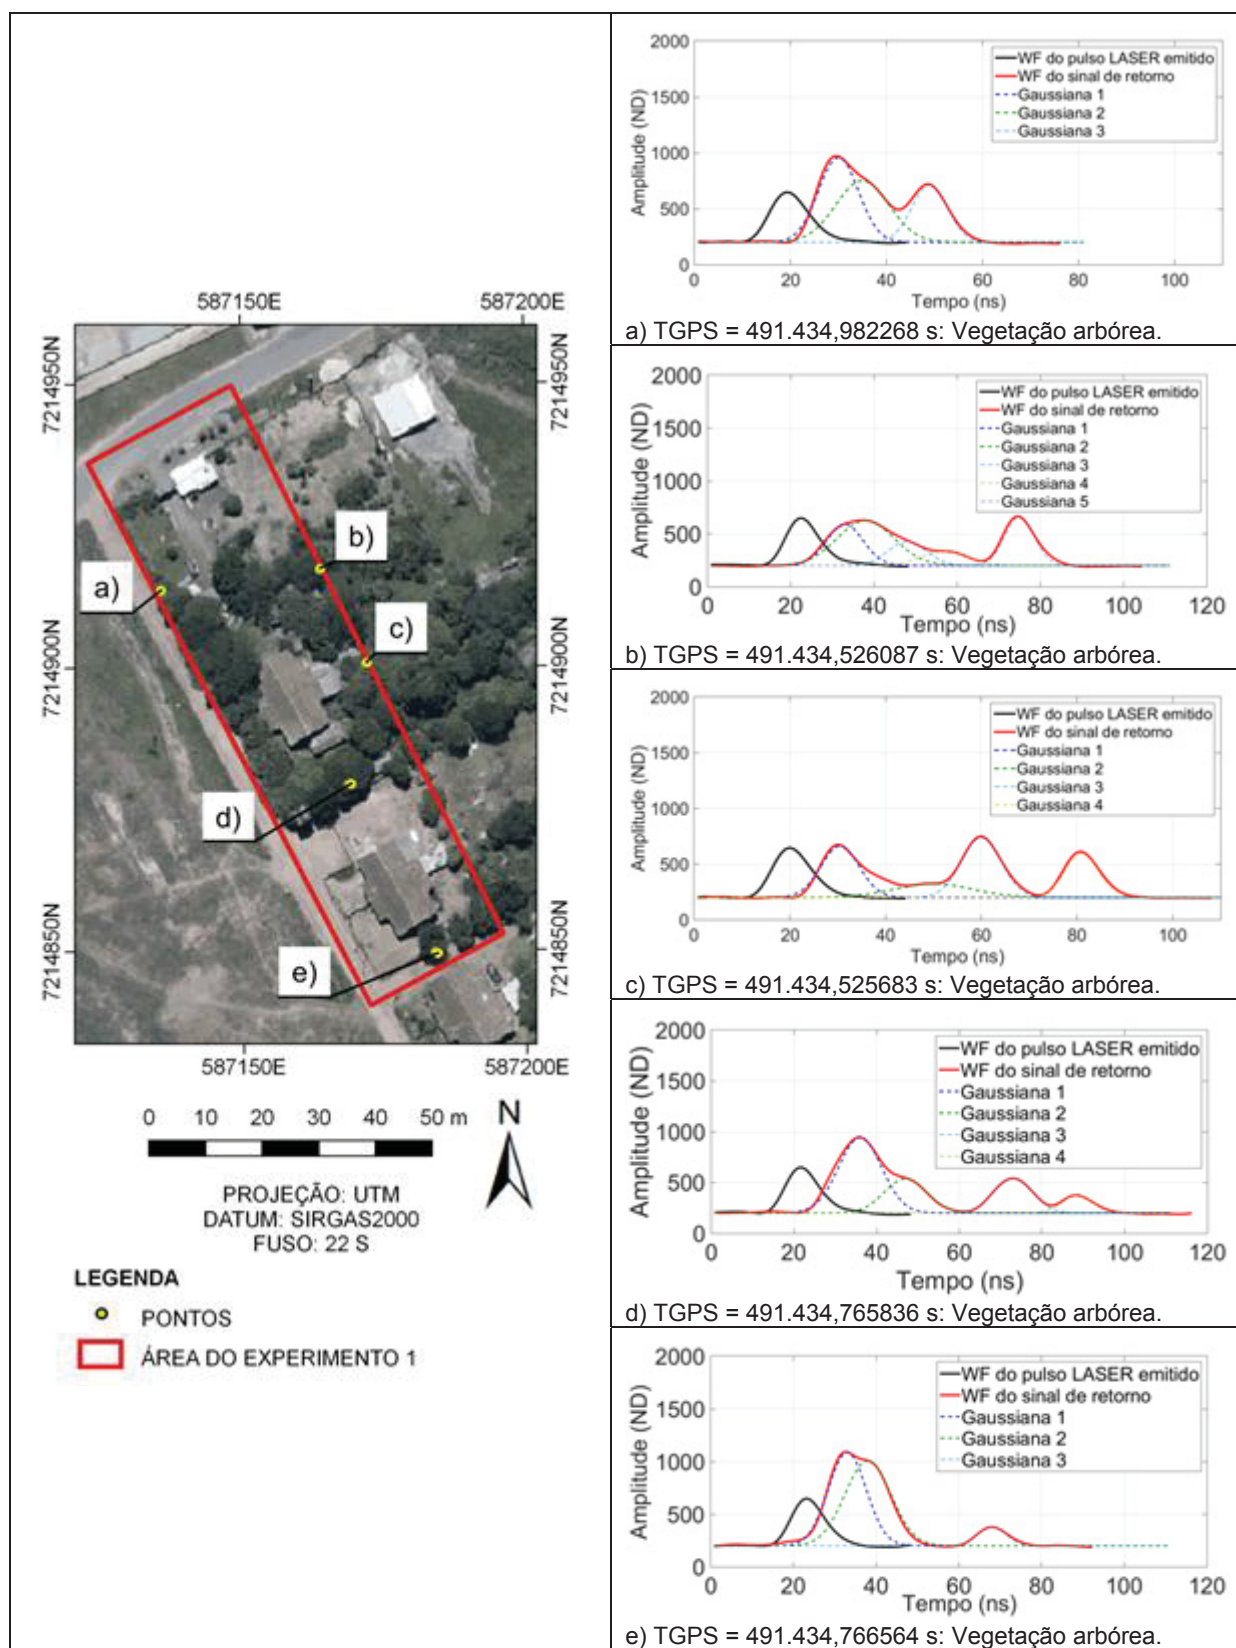
TGPS (s)	NT	NR	A (ND)	μ (ns)	σ	FEIÇÃO
491.434,764452	2	1	1.882	28	3,632016	Telhado de fibrocimento.
491.434,764452	2	2	789	43	3,417546	Solo exposto.
491.434,787788	2	1	2.112	29	3,654650	Telhado de fibrocimento.
491.434,787788	2	2	395	42	3,479390	Solo exposto.
491.434,852564	2	1	1.690	30	3,555456	Telhado de cerâmica.
491.434,852564	2	2	639	55	3,109694	Solo exposto.
491.434,766112	2	1	1.601	30	3,689952	Telhado de cerâmica.
491.434,766112	2	2	399	65	3,535864	Solo exposto.
491.434,766440	2	1	1.279	28	3,625628	Telhado de cerâmica.
491.434,766440	2	2	746	65	3,348325	Solo exposto.

Fonte: O Autor (2018).

No Quadro 4.3 as WFs das quinas do telhado de fibrocimento apresentaram maiores valores de amplitude em comparação com os telhados de cerâmica, o valor máximo foi de 2.112 ND, a sobreposição destes picos foi causada pela pequena diferença de tempo igual a 13 ns, sendo esta a menor distância inclinada entre picos e também em relação ao terreno. Para os telhados de cerâmica, as WFs apresentaram-se com picos mais espaçados e bem definidos, sendo a maior diferença de tempo entre o primeiro e segundo picos igual a 37 ns identificada na WF com TGPS de 491.434,766440 s. Esta WF é representada na Figura 4.9e, o ponto mais próximo da cumeeira da edificação, e conseqüentemente mais afastado do solo exposto iluminado pelo mesmo feixe. Os segundos retornos das WFs ilustradas na Figura 4.9 apresentaram amplitudes variando de 395 a 789 ND. Estes valores são mais baixos que a metade do valor de 1.946 ND do retorno gerado por reflexão direta do feixe LASER pelo solo exposto, conforme a WF identificada com o TGPS de 491.434,916360 s no Quadro 4.2. Os valores de desvio padrão para solo exposto provenientes de segundos retornos aumentaram em relação ao de retorno único, sendo o maior valor de 3,535864 na WF com TGPS igual a 491.434,766112 s.

A Figura 4.10 ilustra WFs com retornos múltiplos, geradas pela reflexão do feixe LASER por vegetação arbórea.

FIGURA 4.10 – WFS GERADAS POR VEGETAÇÃO ARBÓREA



Fonte: O Autor (2018).

Na decomposição Gaussiana foram detectados três picos sobrepostos na WF da Figura 4.10a que correspondem a diferentes superfícies atingidas na vegetação arbórea. Nas Figuras 4.10b e 4.10c as amplitudes dos picos estão abaixo de 750 ND e quase na mesma altura, indicando que os alvos refletiram o feixe LASER de forma similar, ambas apresentam no final das WFs picos gerados por solo exposto, separados por mínimos locais com amplitudes de aproximadamente 200 ND, sendo de 18 e 21 ns a diferença de tempo destes picos e os imediatamente anteriores. A WF ilustrada na Figura 4.10d apresenta um ponto de mínimo local acentuado que separa o segundo e terceiro picos, com diferença de tempo de 26 ns, isto caracteriza um extrato de vegetação diferente que refletiu o feixe gerando o terceiro pico. Na Figura 4.10e a maior parte da energia do sinal está nos dois primeiros picos, o restante foi digitalizado no terceiro pico e corresponde a solo exposto. As WFs de vegetação arbórea apresentam picos sobrepostos e com amplitudes baixas, isto ocorre devido às características da vegetação com diferentes espécies. No Quadro 4.4 estão os parâmetros determinados na decomposição Gaussiana com AG.

QUADRO 4.4 – PARÂMETROS DAS WFS DE VEGETAÇÃO ARBÓREA

TGPS (s)	NT	NR	A (ND)	μ (ns)	σ	FEIÇÃO
491.434,982268	3	1	961	29	4,149275	Vegetação arbórea.
491.434,982268	3	2	752	34	5,528143	Vegetação arbórea.
491.434,982268	3	3	715	48	3,915096	Vegetação arbórea.
491.434,526087	5	1	590	32	4,392523	Vegetação arbórea.
491.434,526087	5	2	627	37	6,789178	Vegetação arbórea.
491.434,526087	5	3	448	47	4,600901	Vegetação arbórea.
491.434,526087	5	4	335	56	5,471283	Vegetação arbórea.
491.434,526087	5	5	759	74	3,525664	Solo exposto.
491.434,525683	4	1	665	29	3,982106	Vegetação arbórea.
491.434,525683	4	2	323	49	8,111755	Vegetação arbórea.
491.434,525683	4	3	740	59	4,098164	Vegetação arbórea.
491.434,525683	4	4	692	80	3,503599	Solo exposto.
491.434,765836	4	1	945	35	5,201347	Vegetação arbórea.
491.434,765836	4	2	539	46	5,098171	Vegetação arbórea.
491.434,765836	4	3	542	72	4,595478	Vegetação arbórea.
491.434,765836	4	4	375	87	3,600281	Solo exposto.
491.434,766564	3	1	1.091	32	4,581592	Vegetação arbórea.
491.434,766564	3	2	1.010	37	5,531755	Vegetação arbórea.
491.434,766564	3	3	379	67	3,414782	Solo exposto.

Fonte: O Autor (2018).

No Quadro 4.4 os retornos de solo exposto localizados abaixo de vegetação arbórea apresentaram amplitudes menores, variando de 375 a 759 ND, quando comparados à amplitude de 1.946 ND da WF gerada por retorno único ilustrada na Figura 4.8e, os desvios padrão também foram maiores, com valor máximo observado de 3,600281 da WF com TGPS igual a 491.434,765836.

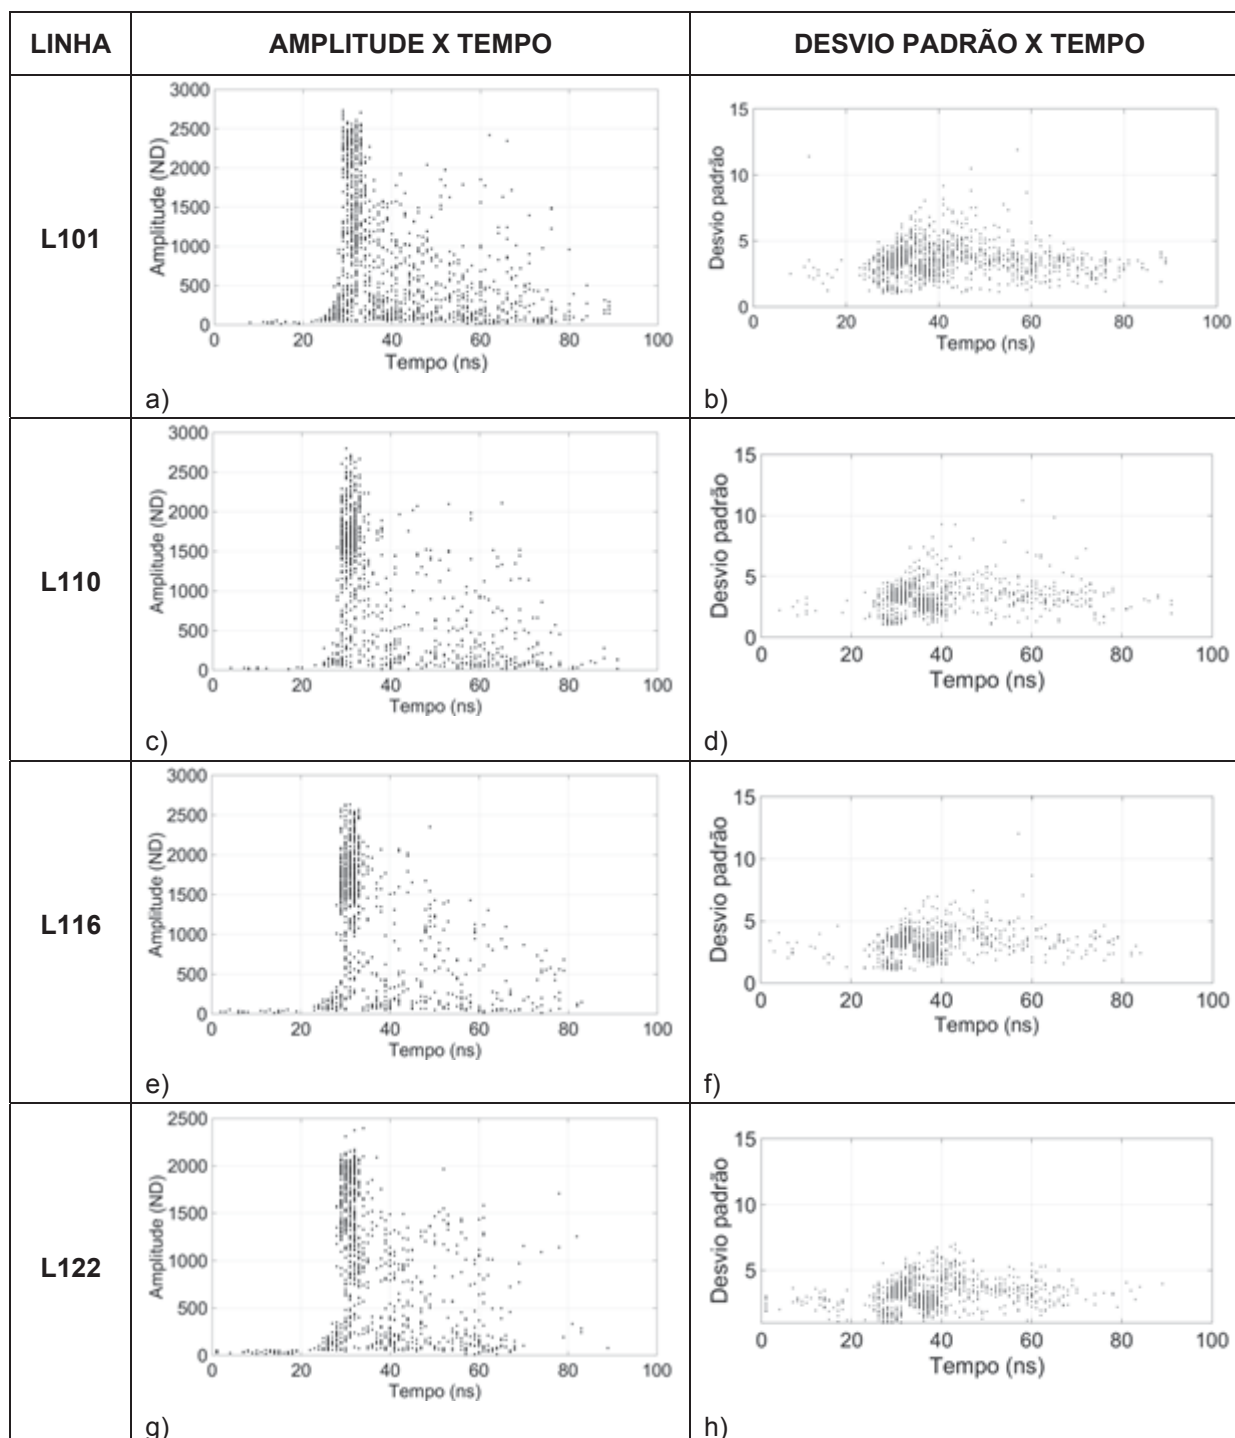
4.3 CLASSIFICAÇÃO FUZZY

Esta etapa foi realizada com abordagem Fuzzy devido à incerteza na determinação de limites rígidos para os parâmetros de amplitude e desvio padrão, estes foram utilizados para classificar os pontos nas seguintes classes:

- Estrada de Asfalto (EA);
- Solo Exposto (SE);
- Telhado de Cerâmica (TC);
- Telhado de Fibrocimento (TF);
- Vegetação Arbórea (VA);
- Vegetação Rasteira (VR).

Na classe de vegetação arbórea foram incluídos arbustos e demais tipos de vegetação localizadas acima do nível do terreno. Visando a definição das variáveis linguísticas para a inferência Fuzzy analisaram-se possíveis agrupamentos dos pontos considerando os valores de amplitude e desvio padrão. Para isto, foram gerados histogramas destes parâmetros em função do tempo conforme ilustra a Figura 4.11 para as linhas de pontos L101, L110, L116 e L122 contidas na área do Experimento 1. Nos histogramas de amplitudes foi identificado um agrupamento de pontos entre as amplitudes de 900 a 2.700 ND e tempos de 28 a 32 ns, conforme ilustrado na Figura 4.11e. Estes pontos correspondem a retornos únicos, na parte mais alta estão os pontos de vegetação rasteira. Também visualizou-se um agrupamento com amplitudes abaixo de 500 ND. Valores de desvio padrão acima de 5 aparecem em tempos superiores a 32 ns e correspondem a retornos múltiplos provocados por vegetação arbórea, conforme a Figura 4.11d.

FIGURA 4.11 – HISTOGRAMAS DE AMPLITUDE E DESVIO PADRÃO



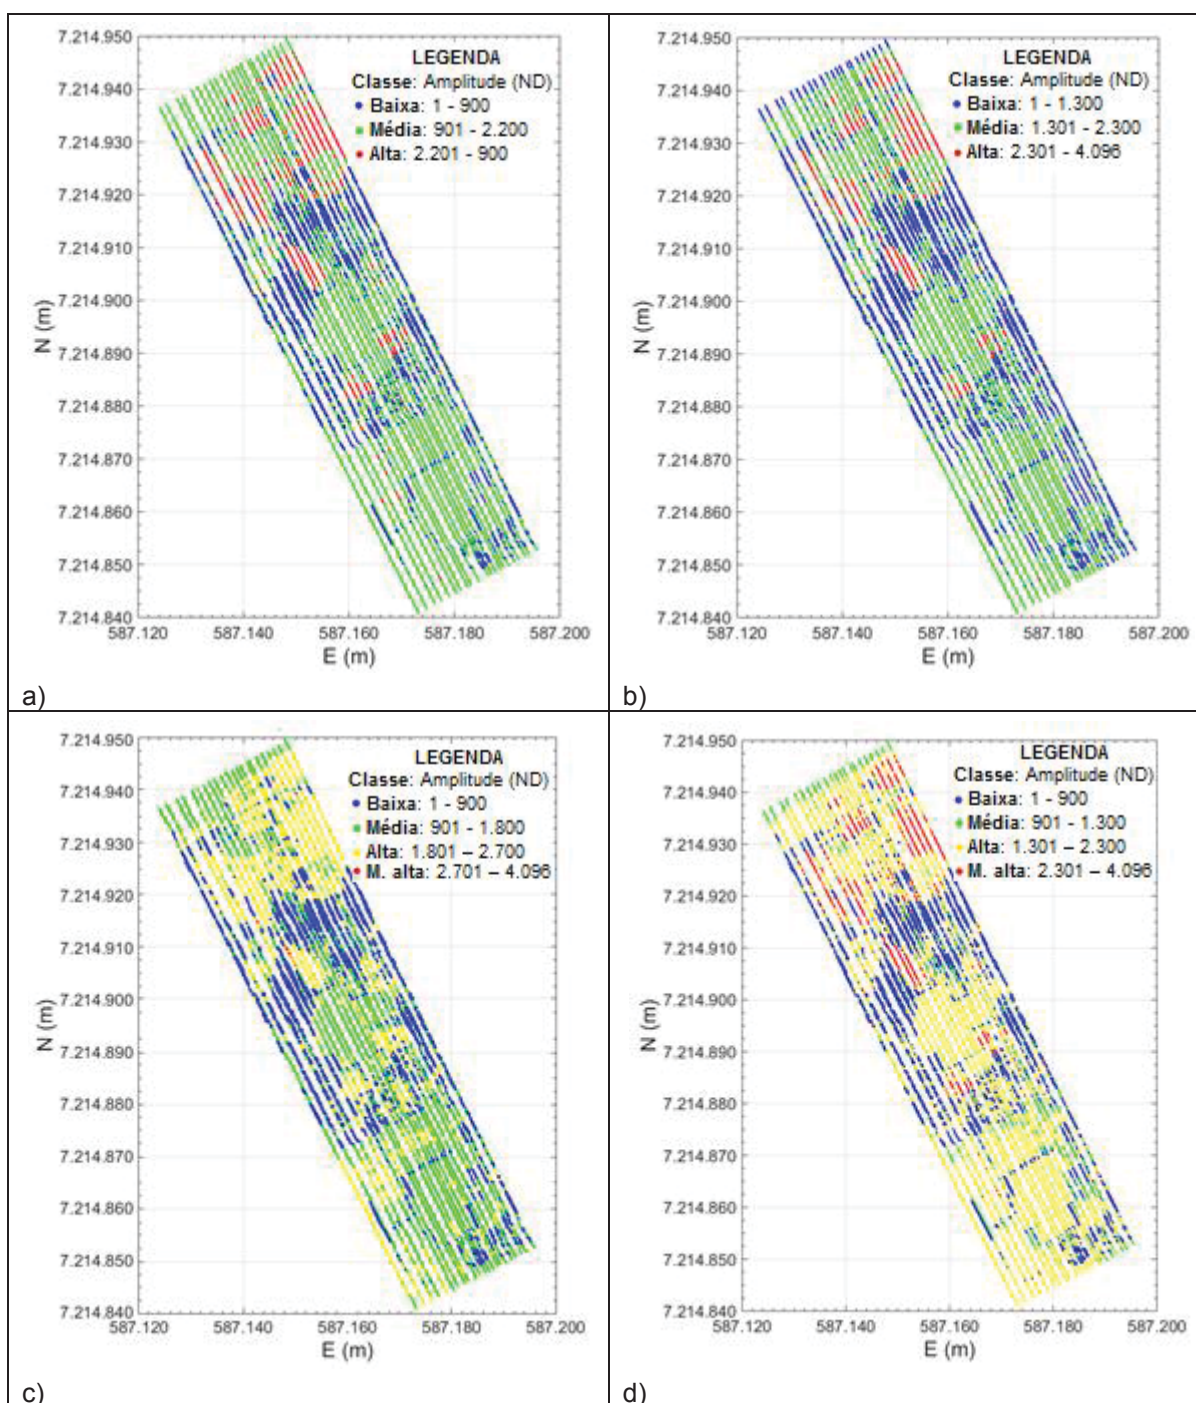
Fonte: O Autor (2018).

Apenas a análise dos histogramas de amplitude e desvio padrão não possibilitou definir os limites rígidos para todas as classes e foram realizadas as análises destes parâmetros de forma separada, conforme descrito nas Seções 4.3.1 e 4.3.2.

4.3.1 Análise de amplitude

As amplitudes dos pontos foram separadas de acordo com as classes rígidas ilustradas na Figura 4.12.

FIGURA 4.12 – CLASSIFICAÇÃO DOS PONTOS POR AMPLITUDE




Fonte: O Autor (2018).

As três classes ilustradas na Figura 4.12a possibilitaram separar a vegetação alta, representada em azul, porém as feições de solo exposto e estrada de asfalto foram representadas em verde, na classe de amplitudes médias. As feições de vegetação rasteira e telhado de fibrocimento foram representadas com a cor vermelha na classe de amplitudes altas. Solo exposto e telhado de cerâmica foram representados em verde na classe de amplitudes médias. As classes das Figuras 4.12b e 4.12d apresentaram boa separação dos pontos da estrada de asfalto e solo exposto, porém confusões ocorreram entre vegetação rasteira e telhado de fibrocimento, solo exposto e telhado de cerâmica, estrada de asfalto e vegetação arbórea. As quatro classes da Figura 4.12d não apresentaram melhor separação das feições quando comparadas com as três classes da Figura 4.12b.

As linhas de pontos L101, L110, L116 e L122 foram representadas em perfil para facilitar a visualização das classes de amplitude. As linhas L101 e L122 estão posicionadas nos extremos da área do Experimento 1 e apresentam pontos nas feições de vegetação arbórea, vegetação rasteira, solo exposto e estrada de asfalto. As linhas L110 e L116 apresentam pontos em todas as feições, incluindo telhado de cerâmica e fibrocimento. A Figura 4.13a ilustra os pontos da linha L101 vistos em perfil, as coordenadas “E” e “N” estão representadas no plano horizontal e as altitudes elipsoidais “h” estão representadas no eixo vertical. As cores dos pontos correspondem aos valores de amplitude do histograma da Figura 4.13b.

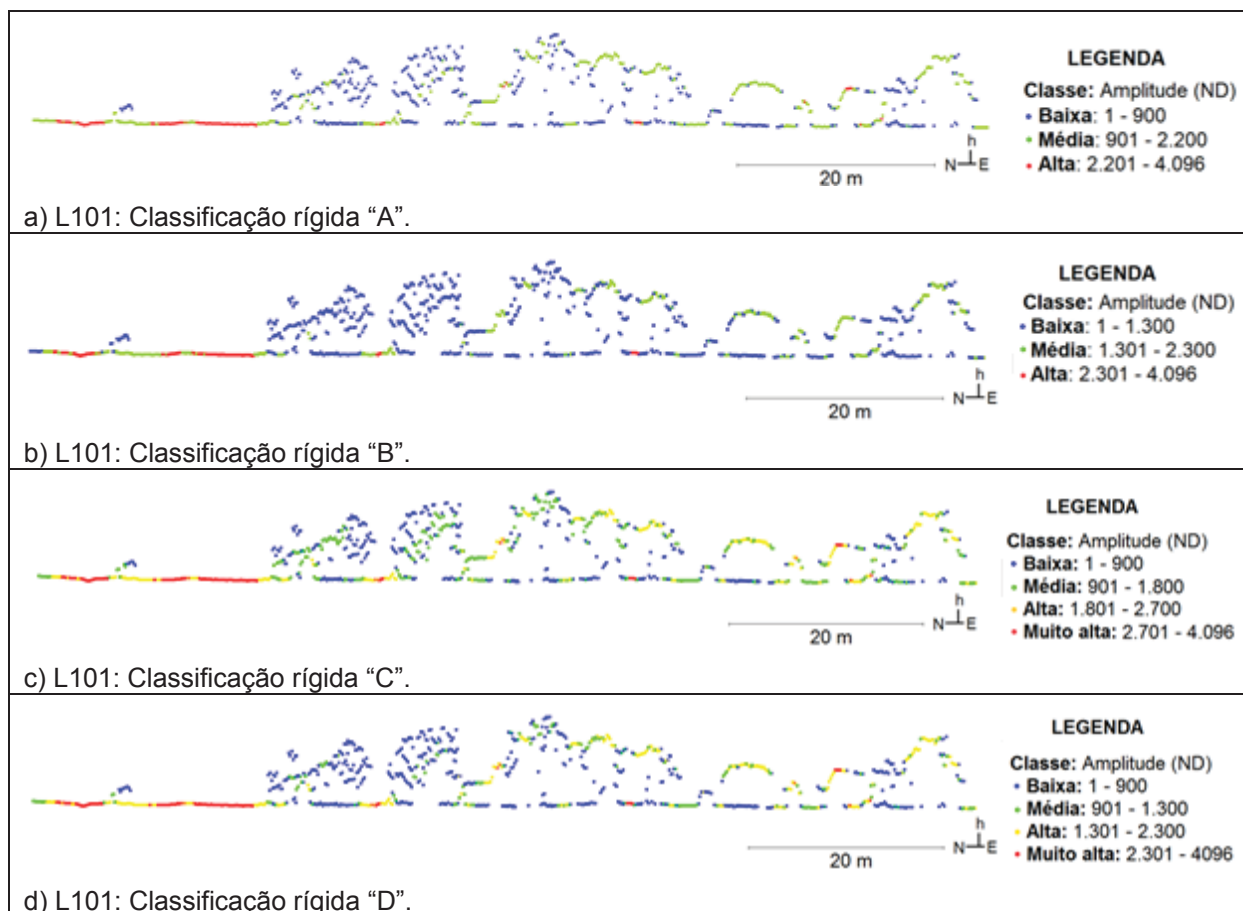
FIGURA 4.13 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L101



Fonte: O Autor (2018).

As Figuras 4.14a, 4.14b, 4.14c e 4.14d ilustram os pontos da linha L101 nas classificações rígidas “A”, “B”, “C” e “D” conforme as classes de amplitudes descritas na Figura 4.12.

FIGURA 4.14 – PONTOS DA LINHA L101 CLASSIFICADOS



Fonte: O Autor (2018).


A estrada de asfalto à esquerda da linha L101 não foi representada em azul na Figura 4.14a, classe das amplitudes baixas, foi representada em verde na classe das amplitudes médias, que correspondem à reflexão do feixe LASER por superfícies com maior refletividade.

Na Figura 4.14b os pontos na cor azul, classe das amplitudes baixas, correspondem às feições de vegetação arbórea, solo exposto abaixo desta vegetação e estrada de asfalto. Os pontos representados na cor verde, classe das amplitudes médias, correspondem a partes de copas de árvores e solo exposto. Os pontos representados na cor vermelha, classe das amplitudes altas, correspondem à vegetação rasteira. Os pontos das classes média e alta são provenientes das superfícies que causaram o retorno único do feixe. Pontos na copa de árvores que anteriormente haviam sido representados com a cor vermelha na Figura 4.14a, foram representados com a cor verde na Figura 4.14b, classe das amplitudes médias, isto indica que os valores definidos nas três classes da Figura 4.14b

representaram melhor as feições, pois a maioria dos pontos de vegetação arbórea apresentam amplitudes baixas e médias, considerando que a energia contida no sinal de retorno foi dividida.

As linhas L110, L116 e L122 também foram classificadas utilizando os limites de amplitudes definidos nas Figuras 4.12a e 4.12b. A Figura 4.15 ilustra o perfil e o histograma dos valores de amplitude para os pontos da linha L110.


FIGURA 4.15 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L110



Fonte: O Autor (2018).

As Figuras 4.16a e 4.16b ilustram os pontos da linha L116 nas classificações rígidas “A” e “B”.

FIGURA 4.16 – PONTOS DA LINHA L110 CLASSIFICADOS




Fonte: O Autor (2018).

Pontos nas copas de árvores da Figura 4.16a foram classificados em amplitudes altas e representados na cor vermelha, considerando as classes da Figura 4.16b, os mesmos pontos foram classificados com amplitudes médias e representados na cor verde, isto fez a classificação ficar mais uniforme para a feição de vegetação arbórea. Na Figura 4.16b os pontos do telhado na edificação à esquerda foram classificados com amplitudes altas e representados em vermelho,

conforme observando na ortofoto na Figura 5.1 este telhado é de fibrocimento, exceção ocorreu com os pontos das quinas representados em azul, estes apresentam menor amplitude devido à reflexão parcial do feixe LASER. Pontos de vegetação rasteira também foram classificados com amplitude alta, a maioria dos pontos de vegetação arbórea foram representados em azul, na classe das amplitudes baixas. Nesta classe também foram representados os pontos próximos das quinas dos telhados.

A Figura 4.17 ilustra o perfil e o histograma dos valores de amplitude dos pontos da linha L116.


FIGURA 4.17 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L116



Fonte: O Autor (2018).

As Figuras 4.18a e 4.18b ilustram os pontos da linha L116 nas classificações rígidas “A” e “B”, respectivamente.


FIGURA 4.18 – PONTOS DA LINHA L116 CLASSIFICADOS



Fonte: O Autor (2018).

A Figura 4.19 ilustra o perfil e o histograma dos valores de amplitude dos pontos da linha L122.


FIGURA 4.19 – PERFIL E HISTOGRAMA DE AMPLITUDES DA LINHA L122



Fonte: O Autor (2018).

As Figuras 4.20a e 4.20b ilustram os pontos da linha L122 nas classificações rígidas “A” e “B”, respectivamente. Novamente na classificação rígida “B” os pontos da estrada de asfalto foram separados da feição de solo exposto.

FIGURA 4.20 – PONTOS DA LINHA L122 CLASSIFICADOS



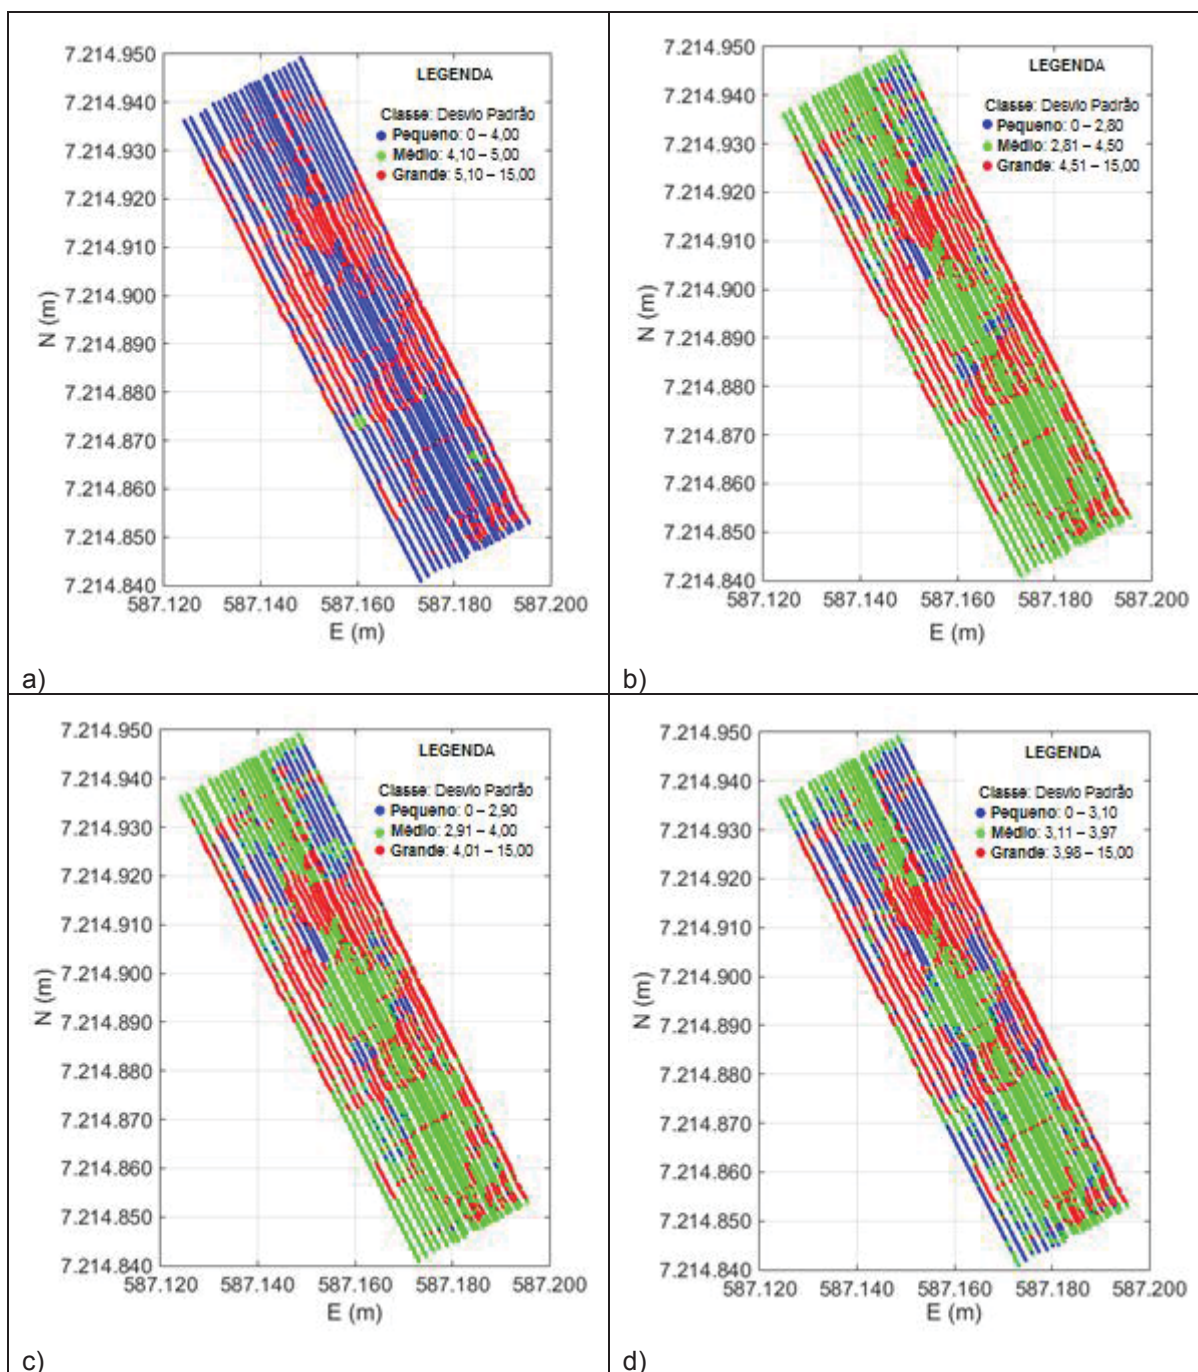
Fonte: O Autor (2018).

Após as análises dos histogramas de amplitude em função do tempo de retorno, das linhas de pontos vistas em planta e perfil e das feições classificadas através dos valores de amplitudes, foram escolhidas as classes da Figura 4.14b como referência para as variáveis linguísticas dos valores de amplitude utilizadas na classificação Fuzzy da nuvem de pontos. Os limites rígidos definidos para as classes de amplitude foram: baixa (1 – 1.300), média (1.301 – 2.300) e alta (2.301 – 4.096). Com estes limites os pontos de estrada de asfalto, quina de telhado e vegetação arbórea foram classificados na classe rígida de amplitudes baixas. Pontos de solo exposto, telhado de cerâmica e vegetação arbórea foram classificados em amplitudes médias. Pontos de telhado de fibrocimento e vegetação rasteira foram classificados em amplitudes altas.

4.3.2 Análise de desvio padrão

A partir da análise das WFs características e dos histogramas de desvio padrão foram definidos os limites para as classes rígidas ilustradas na Figura 4.21.

FIGURA 4.21 – CLASSIFICAÇÃO DOS PONTOS POR DESVIO PADRÃO



Fonte: O Autor (2018).

Na Figura 4.21a os pontos de vegetação arbórea apresentam grandes valores de desvio padrão, porém as demais feições estão na classe de desvio padrão pequeno, restando poucos pontos na classe de desvio padrão médio. As classes das Figuras 4.21b e 4.21c possibilitaram boa separação das feições, no entanto, os pontos de estrada de asfalto e solo exposto apresentaram confusão, o mesmo ocorreu com os pontos de telhado de cerâmica e solo exposto ao redor da edificação. Com as classes da Figura 4.21d houve a melhor separação dos pontos, sendo estes os limites rígidos escolhidos para as classes de desvio padrão: pequeno (0 – 3,10), médio (3,11 – 3,97) e grande (3,98 – 15,00).

4.3.3 Variáveis linguísticas

A partir dos limites rígidos definidos para as classes de amplitude e desvio padrão e análises das WFs características, foram definidas as variáveis linguísticas descritas no Quadro 4.5.

QUADRO 4.5 – VARIÁVEIS LINGUÍSTICAS

PARÂMETRO	VARIÁVEL LINGUÍSTICA	LIMITES	
		INFERIOR	SUPERIOR
Amplitude (ND)	Baixa	0	1.300
	Média	1.068	2.300
	Alta	2.251	4.096
Desvio padrão	Pequeno	0	3,100000
	Médio	2,898665	3,972796
	Grande	3,800000	15,000000

Fonte: O Autor (2018).

Conforme observado na análise das WFs características de quinas de telhados e vegetação arbórea, os picos detectados na última reflexão do feixe LASER por superfícies de solo exposto apresentam valores de amplitudes menores e desvio padrão maiores quando comparados ao detectado em WF com retorno único. Por este motivo, e considerando que na área de estudo não existem pontos da estrada de asfalto gerados por segundos retornos, a classificação foi dividida em duas etapas com regras Fuzzy específicas para classificar os pontos provenientes de WFs com retornos únicos ou múltiplos, e os pontos foram previamente separados de acordo com a quantidade de picos detectados na WF. Realizou-se esta separação para minimizar possíveis confusões, tais como os pontos da estrada de

asfalto com solo exposto determinado em WFs com múltiplos retornos. As regras para a classificação Fuzzy 1 são apresentadas no Quadro 4.6 e foram definidas considerando os pontos gerados a partir de WFs com retornos únicos (RU).

QUADRO 4.6 – REGRAS PARA A CLASSIFICAÇÃO FUZZY 1: RU

Nº	SE:	E:	ENTÃO:
1	Amplitude é "baixa"	Desvio padrão é "pequeno"	Solo exposto.
2	Amplitude é "baixa"	Desvio padrão é "médio"	Estrada de asfalto.
3	Amplitude é "baixa"	Desvio padrão é "grande"	Vegetação arbórea.
4	Amplitude é "média"	Desvio padrão é "pequeno"	Solo exposto.
5	Amplitude é "média"	Desvio padrão é "médio"	Telhado de cerâmica.
6	Amplitude é "média"	Desvio padrão é "grande"	Vegetação arbórea.
7	Amplitude é "alta"	Desvio padrão é "pequeno"	Vegetação rasteira.
8	Amplitude é "alta"	Desvio padrão é "médio"	Telhado de fibrocimento.
9	Amplitude é "alta"	Desvio padrão é "grande"	Vegetação arbórea.

Fonte: O Autor (2018).

As regras para a classificação Fuzzy 2 dos pontos gerados a partir de WFs com retornos múltiplos (RM) são apresentadas no Quadro 4.7.

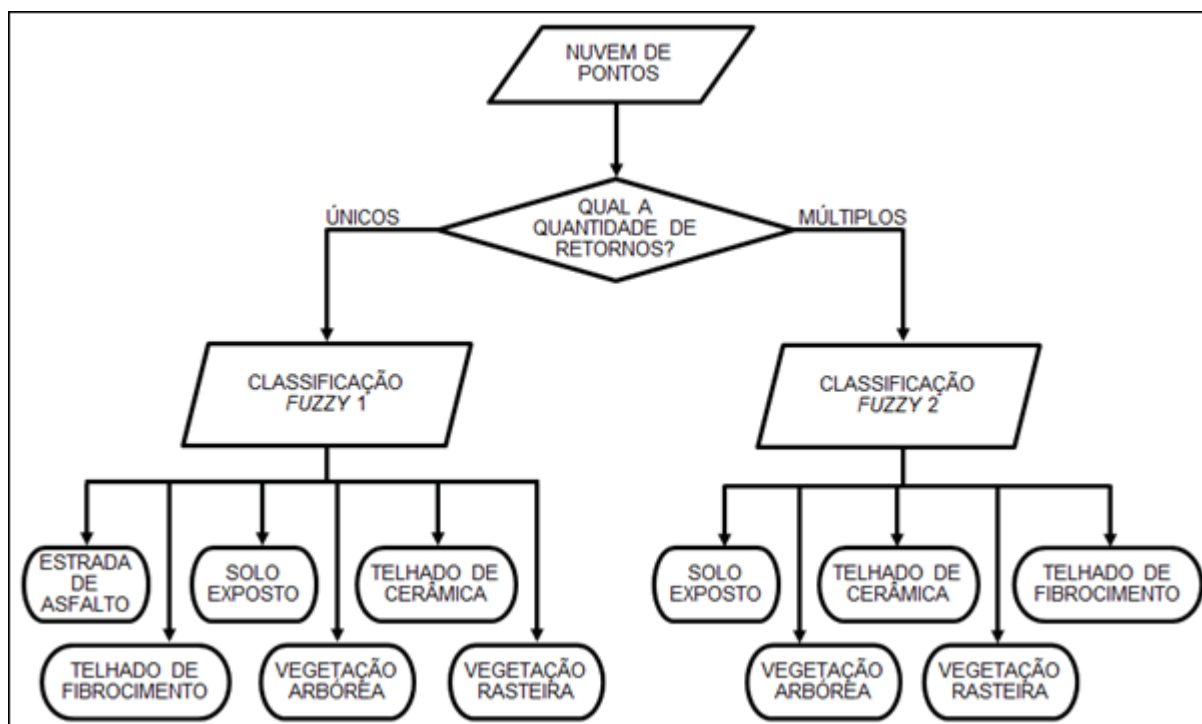
QUADRO 4.7 – REGRAS PARA A CLASSIFICAÇÃO FUZZY 2: RM

Nº	SE:	E:	ENTÃO:
1	Amplitude é "baixa"	Desvio padrão é "pequeno"	Solo exposto.
2	Amplitude é "baixa"	Desvio padrão é "médio"	Solo exposto.
3	Amplitude é "baixa"	Desvio padrão é "grande"	Vegetação arbórea.
4	Amplitude é "média"	Desvio padrão é "pequeno"	Solo exposto.
5	Amplitude é "média"	Desvio padrão é "médio"	Telhado de cerâmica.
6	Amplitude é "média"	Desvio padrão é "grande"	Vegetação arbórea.
7	Amplitude é "alta"	Desvio padrão é "pequeno"	Vegetação rasteira.
8	Amplitude é "alta"	Desvio padrão é "médio"	Telhado de fibrocimento.
9	Amplitude é "alta"	Desvio padrão é "grande"	Vegetação arbórea.

Fonte: O Autor (2018).

As etapas da classificação Fuzzy de acordo com a quantidade de retornos detectados na WF são ilustradas na Figura 4.22.

FIGURA 4.22 – ETAPAS DA CLASSIFICAÇÃO FUZZY



Fonte: O Autor (2018).

4.3.4 Inferência Fuzzy


Para a derivação das conclusões a partir das premissas mostradas nos Quadros 4.6 e 4.7 foram utilizadas funções de pertinência triangulares para cada conjunto considerado. No sistema de inferência Fuzzy os operadores lógicos “E” e “OU” correspondem aos operadores mínimo (mín) e máximo (máx) dos conjuntos a serem combinados e são definidos conforme as Equações (4.6) e (4.7).

$$A \cap B = \text{mín}(A, B) \quad (4.6)$$

$$A \cup B = \text{máx}(A, B) \quad (4.7)$$

O método Mamdani foi aplicado com o operador lógico “mínimo” conforme é ilustrado na Figura 4.23. Neste exemplo foram consideradas apenas as regras 3 e 6 do Quadro 4.6. Na parte esquerda da figura encontram-se as premissas e na direita as conclusões e o resultado atingido, o polígono para a classe de vegetação arbórea.

FIGURA 4.23 – MÉTODO MAMDANI



Fonte: O Autor (2018).

Na primeira etapa as variáveis de entrada foram transformadas em conjuntos Fuzzy, é a nebulização do problema. O grau de pertinência do parâmetro amplitude no conjunto “baixa” é avaliado, como ilustra a primeira função da Figura 4.23. Este grau de pertinência deve ser combinado, na primeira regra, com a premissa “o desvio padrão é grande”, para o qual se utiliza a respectiva função de pertinência. Estas duas condições produzem dois resultados, mostrados com as linhas tracejadas. Como o operador “E” implica em adotar o menor valor das duas premissas, na primeira regra, o valor é o resultante da condição “a amplitude é baixa”. Este valor é usado para cortar a função de pertinência da conclusão “é vegetação arbórea”, do que se deriva um conjunto Fuzzy solução, representado com a área cinza na terceira curva da parte superior da figura. A aplicação da segunda regra segue o mesmo processo, produzindo o segundo conjunto Fuzzy de conclusão conforme ilustrado na parte inferior, o resultado é a combinação destes dois conjuntos através do operador “OU”, conforme é ilustrado no extremo direito da Figura 4.23.

O passo final é a desnebulização, na qual o conjunto Fuzzy resultante foi convertido em um número real através do método do centroide. O valor foi calculado através da Equação 2.33 e corresponde à coordenada do centroide deste conjunto Fuzzy.

4.4 AVALIAÇÃO DA QUALIDADE DA CLASSIFICAÇÃO

A avaliação da qualidade da classificação dos pontos foi realizada através da matriz de confusão, também denominada matriz de erros, ilustrada com o Quadro 4.8. De acordo com Richards e Jia (2006) a qualidade da classificação realizada em um mapa pode ser avaliada através da comparação com amostras das classes consideradas verdades de campo.

QUADRO 4.8 – MATRIZ DE CONFUSÃO

		Classes: verdade de campo			Total de pontos: classificados no mapa
		A	B	C	
Classes: mapa	A	35	2	2	39
	B	10	37	3	50
	C	5	1	41	47
Total de pontos: verdades de campo		50	40	46	136

FONTE: Richards e Jia (2006).

A acurácia do ponto de vista do produtor do mapa (AP) é calculada através da Equação (4.8), uma razão entre o total de pontos classificados corretamente, o elemento posicionado na diagonal principal da matriz (D_{ii}) de confusão, e o somatório dos pontos em coluna (SC_i).

$$AP = \frac{D_{ii}}{SC_i} \quad (4.8)$$

Considerando a classe “B” do Quadro 4.8, 37 pixels foram classificados corretamente, este é o elemento da diagonal principal, representa 92,5 % (37/40) de acerto e corresponde à acurácia do produtor do mapa.

A acurácia do ponto de vista do usuário do mapa (AU) é calculada através da Equação (4.9). Corresponde ao total de pontos classificados corretamente (D_{ii}), dividido pelo somatório dos pontos em linha (SL_i).

$$AU = \frac{D_{ii}}{SL_i} \quad (4.9)$$

A acurácia do usuário da classe “B” do Quadro 4.8 corresponde a 74,0 % (37/50).

Os erros de omissão (EO) estão associados à exatidão do ponto de vista do produtor do mapa, representam os pontos que foram omitidos da classe correta e classificados em outras classes. Este erro é calculado através da Equação (4.10), relaciona o somatório dos pontos classificados em cada coluna (SC_i) com o valor do elemento (D_{ii}) posicionado na diagonal principal da matriz de confusão.

$$EO = \frac{SC_i - D_{ii}}{SC_i} \quad (4.10)$$

Os erros de inclusão (EI) correspondem a pontos de outras classes que foram incluídos erroneamente na classe analisada, estão associados à exatidão do ponto de vista do usuário do mapa e podem ser calculados através da Equação (4.11), que relaciona o somatório dos pontos classificados em linhas (SL_i) com o valor do elemento da diagonal principal (D_{ii}) que corresponde à classe analisada.

$$EI = \frac{SL_i - D_{ii}}{SL_i} \quad (4.11)$$

Os erros de omissão e inclusão da classe “B” do Quadro 4.8 são, respectivamente, 7,5 % e 26,0 %. A partir do somatório dos elementos ($\sum_{i=1}^c D_{ii}$) da diagonal principal da matriz de confusão, número total de pontos (n) e número de classes (c) é possível estimar a acurácia global (AG) da classificação, conforme a Equação (4.12).

$$AG = \frac{\sum_{i=1}^c D_{ii}}{n} \quad (4.12)$$

A acurácia global da classificação ilustrada com o Quadro 4.8 corresponde a 83,1 %. O coeficiente Kappa (K) é igual a 0,75 e foi calculado através da Equação (4.13).

$$K = \frac{n \sum_{i=1}^c D_{ii} - \sum_{i=1}^c SC_i \cdot SL_i}{n^2 - \sum_{i=1}^c SC_i \cdot SL_i} \quad (4.13)$$

Segundo Landis e Koch (1977) é possível utilizar o coeficiente Kappa para avaliar o desempenho da classificação de acordo com as faixas de limites descritas no Quadro 4.9.

QUADRO 4.9 – CLASSES DE DESEMPENHO COM O COEFICIENTE KAPPA

Coeficiente Kappa (K)	Desempenho
< 0,00	Péssimo
0,00 - 0,20	Ruim
0,21 - 0,40	Razoável
0,41 - 0,60	Moderado
0,61 - 0,80	Bom
0,81 - 1,00	Excelente

FONTE: Landis e Koch (1977).

Nesta tese, como verdades de campo, foram utilizados polígonos de referência digitalizados sobre as feições de interesse na ortofoto da área de estudo. Para avaliar o acerto os pontos classificados foram projetados sobre estes polígonos.

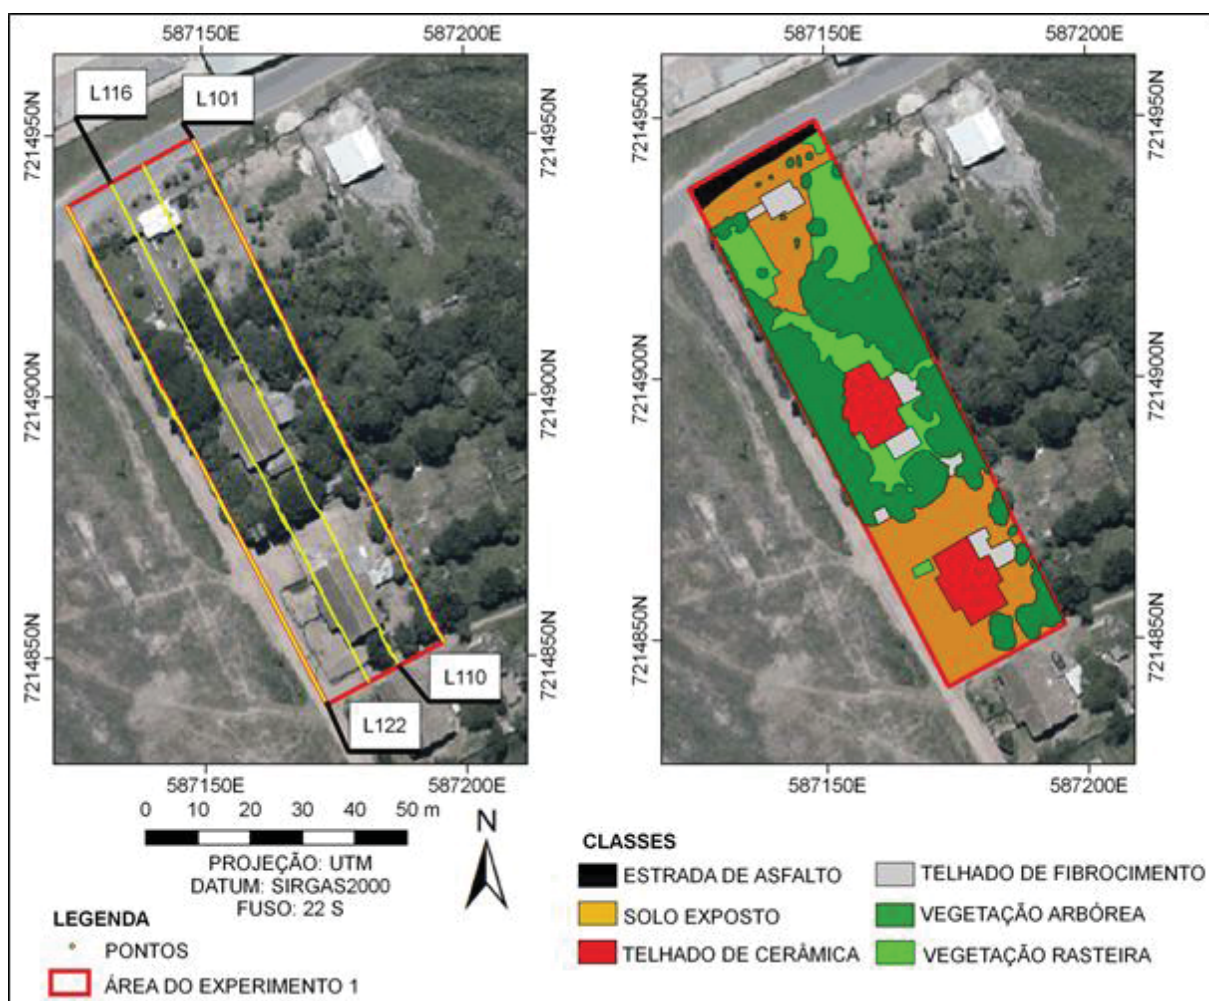
5 RESULTADOS E ANÁLISES

Com o objetivo de validar a metodologia proposta para a geração e classificação da nuvem de pontos foram realizados dois experimentos, os resultados obtidos são apresentados nas Seções 5.1 e 5.2.

5.1 EXPERIMENTO 1

A área do Experimento 1 contém 22 linhas de pontos, codificadas de L101 a L122. A Figura 5.1 ilustra o posicionamento das linhas L101, L110, L116 e L122, além dos polígonos de referência para as classes que foram vetorizados a partir da ortofoto.

FIGURA 5.1 – ÁREA DO EXPERIMENTO 1



Fonte: O Autor (2018).

O polígono vermelho da Figura 5.1 apresenta área igual a 3.638,972 m² e os polígonos que representam a vegetação arbórea, em verde escuro, apresentam área total de 1.028,775 m², o que corresponde a 28,3 % da área de estudo no Experimento 1. Na Tabela 5.1 são apresentados os quantitativos de pontos gerados no software DDR e através da metodologia de DG com AG.

TABELA 5.1 – QUANTITATIVO DE PONTOS DO EXPERIMENTO 1


LINHA	TOTAL		AUMENTO	
	DDR	DG	ABSOLUTO	RELATIVO (%)
L101	1.004	1.239	235	23,4
L102	917	1.099	182	19,8
L103	865	1.038	173	20,0
L104	775	828	53	6,8
L105	742	835	93	12,5
L106	793	925	132	16,6
L107	839	966	127	15,1
L108	807	939	132	16,4
L109	786	906	120	15,3
L110	769	879	110	14,3
L111	781	893	112	14,3
L112	776	932	156	20,1
L113	770	870	100	13,0
L114	720	808	88	12,2
L115	674	751	77	11,4
L116	746	882	136	18,2
L117	830	1.006	176	21,2
L118	850	992	142	16,7
L119	862	1.068	206	23,9
L120	808	926	118	14,6
L121	916	1.113	197	21,5
L122	850	1.006	156	18,2

Fonte: O Autor (2018).

O número de pontos aumentou em todas as linhas da Tabela 5.1. Considerando a nuvem de pontos do software DDR, houve aumento de 3.021 pontos, o que corresponde ao aumento relativo de 16,9 %, calculado considerando os 17.880 pontos gerados com o software DDR e os 20.901 pontos gerados através da metodologia proposta.

As Figuras 5.2a e 5.2b ilustram, respectivamente, o perfil da linha de pontos L101 gerada com o software DDR e com a metodologia.

FIGURA 5.2 – PERFIL DA LINHA L101




Fonte: O Autor (2018).

A circunferência vermelha 1 da Figura 5.2b destaca uma área onde não houve aumento significativo na quantidade de pontos. A circunferência vermelha 2 destaca uma área com vegetação arbórea onde o aumento na quantidade de pontos é visível, principalmente entre a copa da árvore e o extrato mais baixo.

Posteriormente realizou-se a classificação da nuvem de pontos com abordagem Fuzzy utilizando os parâmetros de amplitude e desvio padrão. A Figura 5.3 ilustra a nuvem de pontos classificada no Experimento 1. A qualidade da classificação foi avaliada através da matriz de confusão apresentada na Tabela 5.2.

FIGURA 5.3 – NUVEM DE PONTOS CLASSIFICADA DO EXPERIMENTO 1



Fonte: O Autor (2018).

TABELA 5.2 – MATRIZ DE CONFUSÃO DO EXPERIMENTO 1

		POLÍGONOS DE REFERÊNCIA (ORTOFOTO)							Acurácia do Usuário (%)
		EA	SE	TC	TF	VA	VR	Σ Linhas	
PONTOS CLASSIFICADOS	EA	481	65	6	0	31	26	609	79,0
	SE	52	3.902	168	21	327	98	4.568	85,4
	TC	3	148	1.285	28	105	51	1.620	79,3
	TF	0	15	11	618	36	75	755	81,9
	VA	35	276	85	29	9.425	525	10.375	90,8
	VR	8	129	34	36	502	2.265	2.974	76,2
	Σ Colunas	579	4.535	1.589	732	10.426	3.040	20.901	
Acurácia do Produtor (%)		83,1	86,0	80,9	84,4	90,4	74,5		
Acurácia Global (%)		86,0							
Coeficiente Kappa		0,79							

Fonte: O Autor (2018).

A acurácia global da classificação dos pontos da no Experimento 1 foi de 86,0 % com coeficiente Kappa de 0,79, de acordo com os limites descritos no Quadro 4.9 a classificação pode ser considerada “boa”. Os erros de omissão (EO) e inclusão (EI) para as classes são apresentados na Tabela 5.3.

TABELA 5.3 – ERROS DE OMISSÃO E INCLUSÃO NO EXPERIMENTO 1

CLASSE	EO (%)	EI (%)
EA	20,4	21,0
SE	14,0	14,6
TC	23,7	20,7
TF	15,6	18,1
VA	18,2	10,1
VR	25,5	23,8

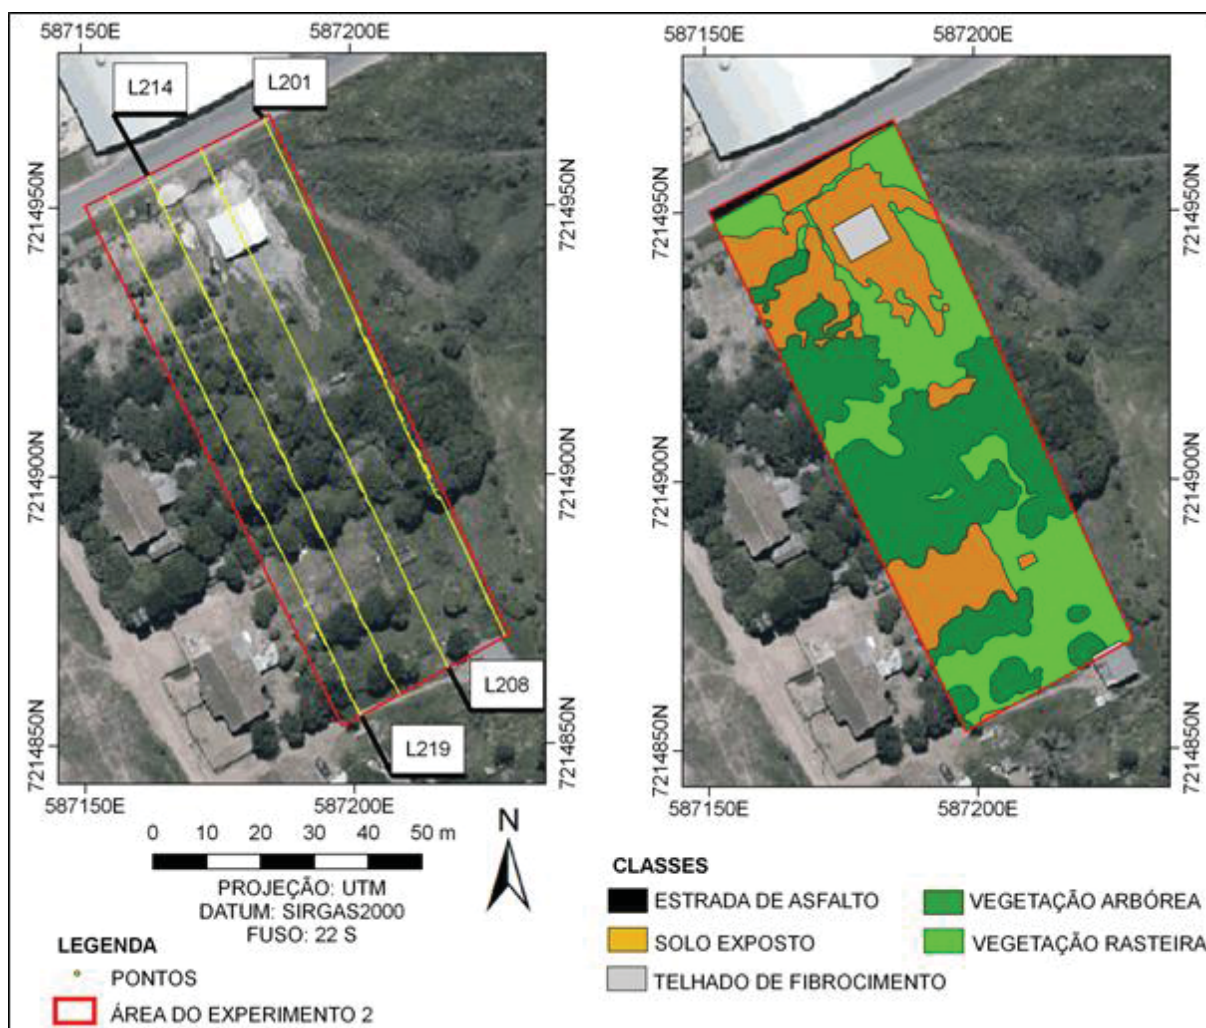
Fonte: O Autor (2018).

A Tabela 5.3 demonstra que a classe de vegetação rasteira (VR) apresentou os maiores erros de omissão e inclusão, respectivamente de 25,5 % e 23,8 %, considerando a matriz de confusão apresentada na Tabela 5.2, houve grande confusão dos pontos desta classe com os pontos de vegetação arbórea (VA). A classe de Telhado de Cerâmica (TC) apresentou erros de omissão e inclusão de 23,7 % e 20,7 %, houve grande confusão dos pontos desta com os pontos da classe de Solo Exposto (SE). A classe de Estrada de Asfalto apresentou erros de omissão e inclusão de 20,4 % e 21,70 % e também houve grande confusão dos pontos desta com os pontos da classe de Solo Exposto (SE).

5.2 EXPERIMENTO 2

A área do Experimento 2 também apresenta 22 linhas de pontos, codificadas de L201 a L222. A Figura 5.4 ilustra o posicionamento das linhas L201, L208, L214 e L219, além dos polígonos de referência para as classes que foram vetorizados a partir da ortofoto.

FIGURA 5.4 – ÁREA DO EXPERIMENTO 2



Fonte: O Autor (2018).

O polígono vermelho da Figura 5.4 apresenta área igual a 3.940,087 m² e os polígonos que representam a vegetação arbórea, em verde escuro, apresentam área total de 1.527,231 m², o que corresponde a 38,8 % da área de estudo no Experimento 2. Na Tabela 5.4 são apresentados os quantitativos de pontos gerados no software DDR e através da metodologia de DG com AG.

TABELA 5.4 – QUANTITATIVO DE PONTOS DO EXPERIMENTO 2


LINHA	TOTAL		AUMENTO	
	DDR	DG	ABSOLUTO	RELATIVO (%)
L201	831	974	143	17,2
L202	894	1042	148	16,6
L203	873	1041	168	19,2
L204	748	866	118	15,8
L205	770	889	119	15,5
L206	745	842	97	13,0
L207	729	803	74	10,2
L208	673	734	61	9,1
L209	751	880	129	17,2
L210	714	815	101	14,1
L211	793	923	130	16,4
L212	841	1012	171	20,3
L213	823	1001	178	21,6
L214	834	986	152	18,2
L215	901	1076	175	19,4
L216	868	1021	153	17,6
L217	851	1031	180	21,2
L218	785	944	159	20,3
L219	805	1031	226	28,1
L220	764	908	144	18,8
L221	823	1001	178	21,6
L222	910	1109	199	21,9

Fonte: O Autor (2018).

O número de pontos também aumentou em todas as linhas da Tabela 5.4. A nuvem de pontos gerada com a metodologia apresentou aumento absoluto de 3.203 pontos em relação aos pontos gerados no software DDR, isto corresponde ao aumento relativo de 18,1 % que foi calculado considerando os 20.929 pontos gerados através da metodologia e os 17.726 pontos do software DDR. As linhas L208 e L219 apresentaram o menor e o maior aumento relativo de pontos, respectivamente de 9,1 % e 28,1 %. A linha L219 tem mais pontos sobre áreas com vegetação arbórea do que a linha L208 e isto explica o melhor resultado.

A Figura 5.5a ilustra o perfil da linha L219 gerada no software DDR e a Figura 5.5b ilustra o perfil da linha L219 gerada através da metodologia.

FIGURA 5.5 – PERFIL DA LINHA DE PONTOS L219

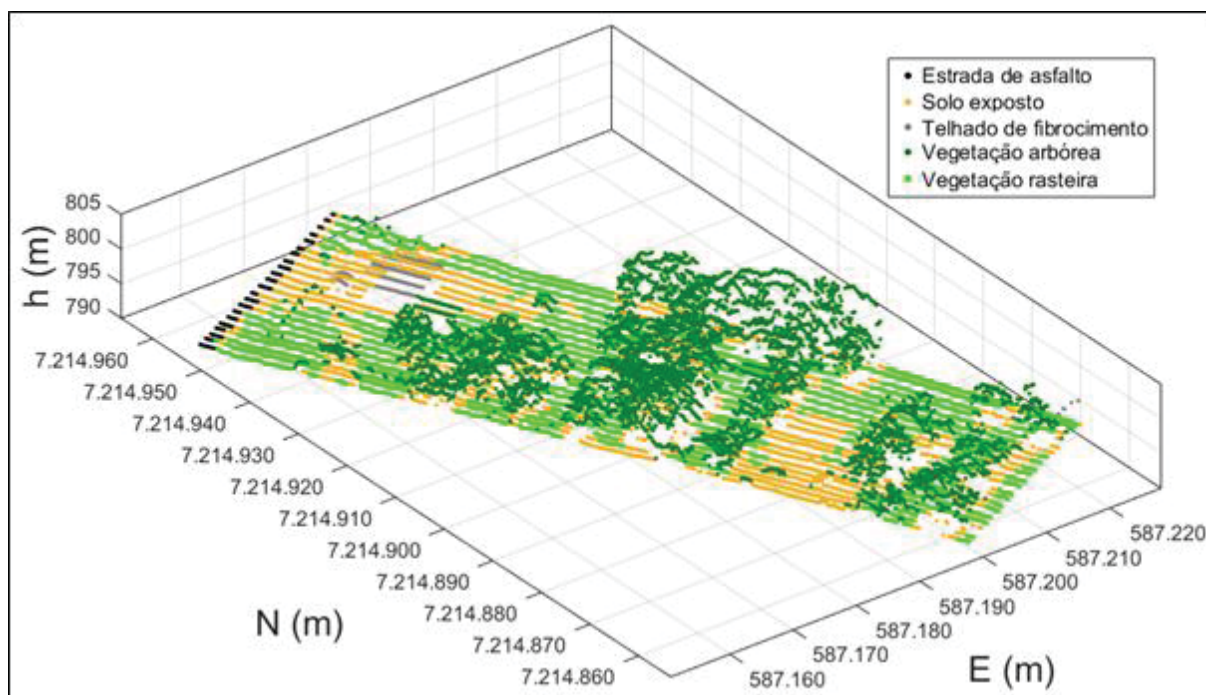


Fonte: O Autor (2018).

A circunferência vermelha com o número 2 da Figura 5.5 destaca o aumento mais significativo na quantidade de pontos na vegetação arbórea do que os pontos isolados da circunferência 1. Após a geração da nuvem de pontos realizou-se a classificação Fuzzy.

A nuvem de pontos classificada no Experimento 2 é ilustrada na Figura 5.6 e a matriz de confusão correspondente é apresentada na Tabela 5.5.

FIGURA 5.6 – NUVEM DE PONTOS CLASSIFICADA DO EXPERIMENTO 2



Fonte: O Autor (2018).

TABELA 5.5 – MATRIZ DE CONFUSÃO DO EXPERIMENTO 2

		POLÍGONOS DE REFERÊNCIA (ORTOFOTO)							Acurácia do Usuário (%)
		EA	SE	TC	TF	VA	VR	\sum Linhas	
PONTOS CLASSIFICADOS	EA	392	45	0	0	18	31	476	80,7
	SE	29	2453	0	21	207	154	2.864	85,6
	TC	0	0	0	0	0	0	0	-
	TF	0	15	0	801	35	75	926	86,5
	VA	26	187	0	25	10.431	845	11.524	90,6
	VR	22	179	0	107	754	4.077	5.139	79,3
	\sum Colunas	469	2.879	0	954	11.445	5.182	20.929	
Acurácia do Produtor (%)		83,6	81,4	-	85,2	84,0	91,1	78,7	
Acurácia Global (%)		86,7							
Coeficiente Kappa		0,79							

Fonte: O Autor (2018).

A classificação dos pontos da área 2 também pode ser considerada boa, pois foi obtida a acurácia global de 86,7 % e coeficiente Kappa de 0,79. Os erros de omissão e inclusão para as classes são apresentados na Tabela 5.6.

TABELA 5.6 – ERROS DE OMISSÃO E INCLUSÃO NO EXPERIMENTO 2

CLASSE	EO (%)	EI (%)
EA	19,6	19,3
SE	14,8	14,4
TF	16,0	13,5
VA	9,5	10,4
VR	21,3	20,7

Fonte: O Autor (2018).

A Tabela 5.6 novamente demonstra que a classe de vegetação rasteira (VR) apresentou os maiores erros de omissão e inclusão, respectivamente de 21,3 % e 20,7 %, considerando a matriz de confusão apresentada na Tabela 5.5, também houve grande confusão dos pontos desta classe com os pontos de vegetação arbórea (VA). A classe de Estrada de Asfalto apresentou erros de omissão e inclusão de 19,6 % e 19,3 % e também houve grande confusão dos pontos desta com os pontos da classe de Solo Exposto (SE).

6 CONSIDERAÇÕES FINAIS

6.1 CONCLUSÕES

Com a metodologia desenvolvida para a decomposição Gaussiana das waveforms com Algoritmos Genéticos foi possível gerar e classificar as nuvens de pontos com os parâmetros de amplitude e desvio padrão determinados. Na etapa inicial da decomposição foi implementado um algoritmo de simples detecção de picos com ponto de máximo local para estimar os parâmetros iniciais. Nas waveforms com um pico detectado foi calculado o desvio padrão a partir das amostras de amplitude e realizou-se a avaliação da modelagem da curva através da função de aptidão. Quando a tolerância de 20 ND não foi atendida, a decomposição foi otimizada com os Algoritmos Genéticos e os parâmetros inicialmente estimados foram utilizados como valores de entrada. Desta forma, além da estimação dos parâmetros iniciais o tempo de processamento de cada linha foi reduzido em 66 %, de aproximadamente uma hora para vinte minutos. Considerando que as waveforms com múltiplos retornos foram geradas pela reflexão do feixe LASER por vegetação arbórea, e que esta representa em média 33,6 % da área de estudo, então 66,4 % da área corresponde a feições que geraram as waveforms com retornos únicos e que não foram processadas, o que confirma a redução no tempo de processamento.

As distâncias inclinadas calculadas com o parâmetro de tempo, determinado na decomposição Gaussiana das waveforms, foram comparadas com as geradas no software comercial DDR e foram consideradas compatíveis, de acordo com a precisão de 0,15 m para as medidas realizadas com a tecnologia LIDAR à taxa amostral de 1 ns. Diferenças nesta ordem de grandeza também podem ocorrer devido ao método utilizado para a detecção do pico. Quando mais picos foram detectados com a metodologia de decomposição em comparação com os determinados no software comercial, diferenças entre 0,15 m e 0,30 m também foram observadas, porém nestes casos a comparação das distâncias ficou prejudicada devido a não ser possível identificar todos os picos. Outro fator que contribui para diferenças nas distâncias calculadas através da metodologia e as medidas diretamente com o sistema ALS no modo discreto, é que estas são relativas ao espelho do sistema de varredura, enquanto a waveform é proveniente

da digitalização do sinal feita externamente, a diferença nos caminhos percorridos provoca atraso na recepção do sinal.

A comparação da quantidade de pontos gerados com a metodologia de decomposição e com o software comercial demonstrou aumento na quantidade de pontos de 16,9 % e 18,1 %, conforme os resultados obtidos nos Experimentos 1 e 2. Os melhores resultados ocorreram em áreas com vegetação arbórea, conforme a linha L218 do Experimento 2 que apresentou aumento de 28,1 % na quantidade de pontos.

Foram definidas waveforms características para as feições de interesse na área de estudo. As feições de vegetação rasteira e telhado de fibrocimento apresentaram os maiores valores de amplitude, seguidas de telhado de cerâmica, solo exposto e estrada de asfalto com o valor mais baixo de amplitude em relação a outras feições que geraram retorno único para o feixe LASER. Nas áreas com vegetação arbórea foram digitalizadas waveforms complexas, com sobreposição de picos, assimetria e amplitudes baixas. Nestes casos a potência diminui ao longo da trajetória do sinal de retorno e torna a modelagem dos últimos picos mais difícil, pois apresentam amplitude baixa e desvio padrão grande. Os maiores valores de desvio padrão foram observados em waveforms geradas por superfícies inclinadas, tais como as folhas de árvores e os telhados das edificações.

Com a análise para a definição dos limites das variáveis linguísticas utilizadas na classificação Fuzzy foi verificado que algumas classes não apresentaram boa separabilidade utilizando apenas o parâmetro de amplitude, tais como “telhado de cerâmica” e “solo exposto”, “telhado de fibrocimento” e “vegetação rasteira”, “estrada de asfalto” e “vegetação arbórea”. Nestes casos, o parâmetro de desvio padrão possibilitou a separação dos pontos, pois os picos das waveforms geradas por superfícies planas apresentaram valores menores que as inclinadas.

As classificações dos pontos realizadas nos Experimentos 1 e 2 apresentaram acurácias globais, respectivamente de 86,0 % e 86,7 %. O coeficiente Kappa foi de 0,79 em ambos os experimentos, sendo considerados bons os resultados obtidos.

6.2 RECOMENDAÇÕES

Com o objetivo de tornar o processo de detecção de picos mais eficiente na decomposição Gaussiana das waveforms com Algoritmos Genéticos, em estudos futuros recomenda-se que sejam testados outros operadores genéticos e diferentes métodos de cruzamento e seleção.

Dependendo das feições contidas na área mapeada, a decomposição da waveform com os Algoritmos Genéticos pode ser realizada com outras funções analíticas para avaliar a aptidão da modelagem, tais como as funções Burr, Gaussiana Generalizada, Nakagami, Lognormal e Weibull. Os parâmetros destas funções também podem ser utilizados na classificação dos pontos em situações específicas.

A tolerância de 20 ND na função de aptidão foi definida considerando que a digitalização da waveform depende de fatores externos, tais como a atmosfera, ruídos presentes no sinal além de imperfeições decorrentes da fabricação do sensor. Recomenda-se que seja analisada a influência destes fatores nos valores de amplitude digitalizados pelo sistema Digitizer considerando a reflectância medida diretamente nas superfícies dos alvos.

Melhores resultados podem ser obtidos na classificação se, complementarmente as informações extraídas das waveforms, forem utilizadas informações espaciais tais como as alturas dos pontos em relação ao terreno, para isto pode ser útil um Modelo Digital de Superfície Normalizado (MDSN). Considerando os casos de confusão ocorridos nos valores de amplitude dos pontos de telhado de cerâmica e solo exposto, uma feição está acima e a outra no nível do terreno, a análise da altura na vizinhança do ponto melhoraria a classificação.

Pontos da classe de vegetação rasteira apresentaram significativa confusão com vegetação arbórea, isto foi verificado na matriz de confusão dos Experimentos 1 e 2, e também com os erros de inclusão, respectivamente de 23,8 % e 20,7 %. Para melhorar a classificação dos pontos nas áreas de vegetação é recomendado a definição de mais classes considerando os tipos vegetação, altura da copa e refletividade das folhas.

Além da comparação das distâncias inclinadas calculadas com a metodologia, uma avaliação posicional dos pontos gerados pode ser realizada utilizando pontos de referência medidos por um sistema TLS ou através de métodos

convencionais da Topografia. Os pontos classificados como feições localizadas no nível do terreno tais como estrada de asfalto, vegetação rasteira e solo exposto, podem ser selecionados e representados em um MDT e a acurácia pode ser avaliada através de pontos de checagem. Os pontos de vegetação arbórea provenientes da metodologia também podem ser complementados com os pontos de referência formando uma nuvem mais densa. Realizando a modelagem destes pontos com voxels é possível estimar o volume e a estrutura vertical da vegetação.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALEXANDER, C.; BOCHER, P. K.; ARGE, L.; SVENNING, J. C. **Regional-scale mapping of tree cover, height and main phenological tree types using airborne laser scanning data**. *Remote Sensing of Environment*, v. 147. p. 156-172, 2014.
- BALTSAVIAS, E. P. **Airborne laser scanning: basic relations and formulas**. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 54. p. 199-214, 1999.
- BIN, X.; FANGFEI, L.; KESHU, Z.; ZONGJIAN, L. **Laser footprint size and pointing precision analysis for LIDAR systems**. *International Archives of Photogrammetric, Remote Sensing and Spatial Information Sciences*, Vol. XXXVII, p. 331-336. Part B1. Beijing, 2008.
- BLAIR, J. B.; RABINE, D. L.; HOFTON, M. A. **The Laser Vegetation Imaging Sensor: a medium-altitude, digitization-only, airborne laser altimeter for mapping vegetation and topography**. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 54, p. 115-122, 1999.
- BRETAR, F.; CHAUVE, A.; MALLET, C.; JUTZI, B. **Managing full waveform LIDAR data: A challenging task for the forthcoming years**. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVII, Part b1, p. 415-420. Beijing, 2008.
- CASALEGNO, S.; ANDERSON K.; HANCOCK, S. **Improving models of urban greenspace: from vegetation surface cover to volumetric survey, using waveform laser scanning**. *Methods in Ecology and Evolution*, v. 8, n. 11, p. 1443-1452, 2017.
- CHAUVE, A.; MALLET, C.; BRETAR, F.; DURRIEU, S.; PIERROT-DESEILLIGNY, M.; PUECH, W. **Processing full-waveform LiDAR data: Modelling raw signals**. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36, Part 3/W52, p. 102-107, 2007.
- CHEN, D.; PEETHAMBARAN, J.; ZHANG, Z. **A supervoxel-based vegetation classification via decomposition and modeling of full-waveform airborne laser scanning data**. *International Journal of Remote Sensing*, v. 39, n. 9, p. 2937-2968, 2018.
- CHENG, H. D.; JIANG, X. H.; SUN, Y.; WANG, J. **Color image segmentation: advances and prospects**. *Pattern Recognition* 34, p. 2259-2281, 2001.
- DONEUS, M.; BRIESE, M.; FERA, M.; JANNER, M. **Archaeological prospection of forested areas using full-waveform airborne laser scanning**. *Journal of Archaeological Science*, 35, n. 4, p. 882-893, 2008.
- DUCIC, V.; HOLLAUS, M.; ULLRICH, A.; WAGNER, W.; MELZER, T. **3D vegetation mapping and classification using full-waveform laser scanning**. In: *Workshop on 3D Remote Sensing in Forestry – Session 8a*, p. 211-217, Vienna, Austria, 14th -15th feb., 2006.

FERRAZ, A.; SAATCHI, S.; MALLET, C.; JACQUEMOUD, S.; GONÇALVES, G.; SILVA, C. A.; SOARES, P.; TOMÉ, M.; PEREIRA, L. **Airborne lidar estimation of aboveground forest biomass in the absence of field inventory**. Remote Sensing, v. 8, 653, p. 1-18, 2016.

FILIN, S. **Analysis and implementation of a laser strip adjustment model**. In: Proceedings of the ISPRS Workshop on 3-D Reconstruction from Airborne Laserscanner and InSAR Data, 8-10 out. 2003, Dresden. 6p.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. New York: Addison – Wesley, 1989. 372 p.

GUMEROV, D. **DTM generation in forested areas from full-waveform airborne lidar data**. 147p. Thesis for the Degree of Master of Science. Graduate Program in Earth and Space Science York University. Toronto, Ontario, Canada, 2014.

HABIB, A. F.; KERSTING, A. P.; RUIFANG, Z.; AL-DURGHAM, M.; KIM, C.; LEE, D. C. **Lidar strip adjustment using conjugate linear features in overlapping strips**. 6 p. In: The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences. Val. XXXVII. Part B1. Beijing, 2008.

HANCOCK, S.; ANDERSON, K.; DISNEY, M.; GASTON, K. J. **Measurement of fine-spatial-resolution 3D vegetation structure with airborne waveform lidar: calibration and validation with voxelised terrestrial lidar**. Remote Sensing of Environment, 188, 37–50, 2017.

HARSDORF, S.; REUTER, R. **Stable deconvolution of noisy lidar signals**. 8 p. In: Proceedings of EARSeL-SIG-Workshop LIDAR, Dresden/FRG, p. 88-95, June 16 – 17, 2000. Germany, 2000.

HOFTON, M. A.; BLAIR, J. B. **Laser altimeter return pulse correlation: a method for detecting surface topographic change**. Journal of Geodynamics, v. 34, p. 477-489, 2002.

JUTZI, B.; STILLA, U. **Range determination with waveform recording LASER systems using a Wiener Filter**. 13 p. ISPRS Journal of Photogrammetry and Remote Sensing, v. 61, p. 95-107, 2006.

KERSTING, A. P. B. **Quality assurance of multi-sensor systems**. 265p. Ph.D. Thesis for Degree of Doctor of Philosophy. Department of Geomatics Engineering, University of Calgary. Canadá, 2011.

LANDIS, R. J., KOCH, G. G. **The measurement of observer agreement for categorical data**. Biometrics, v. 33, p. 159-174, 1977.

LANGE, R. **3D Time-of-Flight distance measurement with custom solid-state image sensors in CMOS/CCD-technology**. 205 p. Dissertation for the degree of Doctor of Technical Sciences, Department of Electrical Engineering and Computer Science at University of Siegen. Siegen, Alemanha, 2000.

LIN, Y. C.; MILLS, J.; VOYSEY, S. S. **Detection of weak and overlapping pulses from waveform airborne laser scanning data**. In: Proceedings of SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory. Heriot-Watt University, Edinburgh, UK, p. 478-487, 17-19 September, 2008.

MALLET, C.; SOERGEL, U.; BRETAR, F. **Analysis of full-waveform lidar data for an accurate classification of urban areas**. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, v. 37 (Part 3A), p. 85-92, 2008.

MALLET, C.; BRETAR, F. **Full-waveform topographic lidar: State-of-the-art**. ISPRS Journal of Photogrammetry and Remote Sensing, v. 64, p. 1-16, 2009.

MALLET, C.; LAFARGE, F.; BRETAR, F.; SOERGEL, U.; HEIPKE, C. **Lidar waveform modeling using a marked point process**. 4 p. 16th IEEE International Conference on Image Processing (ICIP 2009). Cairo, Egypt, 7-10 nov, 2009.

MEANS, J. E.; ACKER, S. A.; HARDING, D. J.; BLAIR, J. B.; LEFSKY, M. A.; COHEN, W. B.; HARMON, M. E.; MCKEE, W. A. **Use of Large-Footprint Scanning Airborne Lidar to Estimate Forest Stand Characteristics in the Western Cascades of Oregon**. Remote Sensing of Environment, 67 (3), p. 298-308, 1999.

MITCHELL, M. **An introduction to Genetic Algorithms**. Cambridge: Mit Press, 1996. 158 p.

MOSTAFA, M. M. R., HUTTON, J. **Direct positioning and orientation systems – how do they work? What is the attainable accuracy?** 11p. Proceedings, American Society of Photogrammetry and Remote Sensing (ASPRS) Annual Meeting. St. Louis, MO, USA, April 22-27, 2001.

NEGNEVITSKY, M. **Artificial Intelligence: A Guide to Intelligent Systems**. 2nd edition. England: Pearson Education, 2005. 415 p.

NIEMEYER, F.; MALLET, C.; ROTTENSTEINER, F.; SÖRGEL, U. **Conditional random fields for the classification of LIDAR point clouds**. 6p. Proceedings, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Hannover, Germany, June, 2011.

NORDIN, L. **Analysis of Waveform Data from Airborne Laser Scanner Systems**. 40p. Thesis for the Degree of Master of Science. Lulea University of Technology. Norrbotten, Sweden, 2006.

OPTECH Incorporated. **ALTM Intelligent Waveform Digitizer – Operation and Processing manual**. 60 p. 0073905 Rev B. Vaughan, Ontario, Canada, 2012a.

OPTECH Incorporated. **Airborne Laser Terrain Mapper Pegasus HD500 – Survey Operation Manual**. 84 p. 0053918 Rev F. Vaughan, Ontario, Canada, 2012b.

OPTECH Incorporated. **Pegasus HD500 – Summary Specification Sheet**. 2 p. Vaughan, Ontario, Canada, 2014.

PIROTTI, F.; GUARNIERI, A.; VETTORE, A. **State of the Art of Ground and Aerial Laser Scanning Technologies for High-Resolution Topography of the Earth Surface**. p. 66-78. European Journal of Remote Sensing, 2013.

QIN, H.; WANG, C.; PAN, F.; LIN, Y.; XI, X.; LUO, S. **Estimation of FPAR and FPAR profile for maize canopies using airborne LIDAR**. Ecological Indicators, v. 83, p. 53-61, 2017.

RICHARDS, A. J.; JIA, X. **Remote Sensing Digital Image Analysis**. Fourth Edition. Berlin: Springer-Verlag, 2006. 439 p.

RISTORCELLI, T.; HAMOIR, D.; BRIOTTET, X. **Simulating space lidar waveforms from smaller-footprint airborne laser scanner data for vegetation observation**. IEEE Geoscience and Remote Sensing Letters, v. 11 (2), p. 534-538, 2014.

RONCAT, A.; WAGNER, W.; MELZER, T.; ULLRICH, A. **Echo detection and localization in full-waveform airborne laser scanner data using averaged square difference function estimator**. The Photogrammetry Journal of Finland, Vol. 21, p. 62-75, 2008.

SCHAER, P. **In-flight quality assessment and data processing for airborne laser scanning**. 166 p. Geodatisch-geophysikalische Arbeiten in der Schweiz, Neunundsiebzigster Band, v. 79, 2010. Originalmente apresentado como tese de doutorado: Thèse N° 4590 (2009), École Polytechnique Fédérale de Lausanne.

SLOTA, M. **Decomposition techniques for full-waveform airborne laser scanning data**. Geomatics and Environmental Engineering, Vol. 8, N° 1, p. 61-74, 2014.

SLOTA, M. **Full-waveform data for building roof step edge localization**. ISPRS Journal of Photogrammetry and Remote Sensing 106, p. 129-144, 2015.

SHAN, J.; TOTH, C. K. **Topographic Laser Ranging and Scanning: Principles and Processing**. CRC Press: Boca Raton, FL. 2009. 590 p.

TSENG, Y.; WANG, C.; CHU, H.; HUNG, Y. **Waveform-based point cloud classification in land-cover identification**. International Journal of Applied Earth Observation and Geoinformation, v. 34. p. 78 – 88, 2015.

TOTH, C. K.; ZALETNYIK, P.; LAKY, S.; GREJNER-BRZEZINSKA, D. **The Potential of Full-waveform LIDAR in Mobile Mapping Applications**. Archives of Photogrammetry, Cartography and Remote Sensing, Vol. 22, p. 401-410, 2011.

VICENT, G.; ANTIN, C.; LAURANS, M.; HEURTEBIZE, J.; DURRIEU, S.; LAVALLEY, C.; DAUZAT, J. **Mapping plant área index of tropical evergreen forest by airborne laser scanning. A cross-validation study using LAI2200 optical sensor**. Remote Sensing of Environment, v. 198, p. 254-266, 2017.

YAN, W. Y.; SHAKER, A.; EL-ASHMAWY, N. **Urban land cover classification using airborne LiDAR data: A review**. Remote Sensing of Environment 158, p. 295-310, 2015.

ZADEH, L. A. **Fuzzy Sets**. Information and Control 8, p. 338-353, 1965.

ZALETNYIK, P.; LAKY, S.; TOTH, C. **LIDAR waveform classification using Self-Organizing Map**. 12 p. ASPRS, San Diego, CA, 28-30 April, 2010.

ZHU, J.; ZHANG, A.; HU, X.; LI, Z. **Analysis and application of LIDAR waveform data using a progressive waveform decomposition method**. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. XXXVIII-5/W12, p. 31-36, 2011.

WAGNER, W.; ULLRICH, A.; MELZER, T.; BRIESE, C.; KRAUS, K. **From Single-Pulse to Full-Waveform Airborne Laser Scanners: Potential and Practical Challenges**. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 35, p. 201-206, Part. B3, 2004.

WAGNER, W.; ULLRICH, A.; DUCIC, V.; MELZER, T.; STUDNICKA, N. **Gaussian decomposition and calibration of a novel small-footprint full-waveform digitizing airborne laser scanner**. ISPRS Journal of Photogrammetry and Remote Sensing 30, p. 100-112, 2006.

WANG, CHENG-KAI.; TSENG, YI-HSING.; WANG, CHI-KUEI. **A Wavelet-Based Echo Detector for Waveform LIDAR Data**. IEEE Transactions on Geoscience and Remote Sensing, Vol. 54, No. 2, p.757-769, 2016.

WEHR, A.; LOHR, U. **Airborne laser scanning – an introduction and overview**. ISPRS Journal of Photogrammetry and Remote Sensing, v. 54, p. 68 – 82, 1999.

WU, J. **A Signal processing approach for preprocessing and 3d analysis of airborne small-footprint full waveform lidar data**. 127p. Thesis for the Degree of Doctor of Philosophy. Chester F. Carlson Center for Imaging Science of the College of Science, Rochester Institute of Technology. Nova York, 2012.